

**PREDIKSI NILAI ANOMALI SUHU PERMUKAAN LAUT  
PADA AREA NINO 3.4 MENGGUNAKAN METODE  
RECURRENT NEURAL NETWORK LONG SHORT-TERM  
MEMORY**

**SKRIPSI**

**Oleh:  
TAUFAN YURI ADRIAN  
155090307111015**



**JURUSAN FISIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS BRAWIJAYA  
MALANG  
2019**



**PREDIKSI NILAI ANOMALI SUHU PERMUKAAN LAUT  
PADA AREA NINO 3.4 MENGGUNAKAN METODE  
RECURRENT NEURAL NETWORK LONG SHORT-TERM  
MEMORY**

**SKRIPSI**

Sebagai Salah Satu Syarat Untuk Meraih Gelar

Sarjana Sains dalam Bidang Fisika

Oleh:

**TAUFAN YURI ADRIAN**

**155090307111015**



**JURUSAN FISIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS BRAWIJAYA  
MALANG**

**2019**





LEMBAR PENGESAHAN SKRIPSI

**PREDIKSI NILAI ANOMALI SUHU PERMUKAAN LAUT  
PADA AREA NINO 3.4 MENGGUNAKAN METODE  
RECURRENT NEURAL NETWORK LONG SHORT-TERM  
MEMORY**


Oleh:

**TAUFAN YURI ADRIAN**


**155090307111015**

Setelah dipertahankan di depan Majelis Penguji  
pada tanggal.....**21 JUN 2019**  
dan dinyatakan memenuhi syarat untuk memperoleh gelar  
Sarjana Sains dalam bidang fisika

Pembimbing I

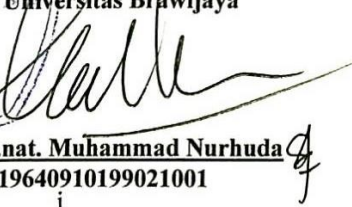
  
**Dr. Eng. Agus Naba, S.Si., MT.**  
**NIP 197208061995121001**

Pembimbing II

  
**Dr. rer.nat. Abdurro'uf, S.Si., M.Si.**  
**NIP 197209031994121001**



Mengetahui,  
Ketua Jurusan Fisika  
**EMIPA Universitas Brawijaya**

  
**Prof. Dr. rer.nat. Muhammad Nurhuda**  
**NIP. 19640910199021001**



(Halaman sengaja dikosongkan)

## LEMBAR PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : **Taufan Yuri Adrian**

NIM : **155090307111015**

Jurusan : **Fisika**

Penulis Skripsi Berjudul :

### **PREDIKSI NILAI ANOMALI SUHU PERMUKAAN LAUT PADA AREA NINO 3.4 MENGGUNAKAN METODE RECURRENT NEURAL NETWORK LONG SHORT-TERM MEMORY**

Dengan ini menyatakan bahwa:

1. Isi dari skripsi yang saya tulis dan saya buat adalah benar-benar karya saya sendiri dan tidak menjiplak karya orang lain, selain nama-nama yang termaktub di isi dan tertulis di daftar pustaka dalam skripsi ini.
2. Apabila di kemudian hari ternyata skripsi yang saya tulis terbukti hasil menjiplak, maka saya akan bersedia menanggung segala resiko yang akan saya terima.

Demikian pernyataan ini dibuat dengan segala kesadaran.

**Malang, 24 Juni 2019**

**Yang Menyatakan,**



**(Taufan Yuri Adrian)**

**NIM. 155090307111015**



RSITAS BRA

(Halaman sengaja dikosongkan)





## PREDIKSI NILAI ANOMALI SUHU PERMUKAAN LAUT

### PADA AREA NINO 3.4 MENGGUNAKAN METODE RECURRENT NEURAL NETWORK LONG SHORT-TERM MEMORY ABSTRAK

Memprediksi nilai anomali suhu permukaan laut (SST) di wilayah Nino telah dilakukan oleh berbagai institusi, karena fenomena El Niño Southern Oscillation (ENSO) yang terjadi pada area tersebut menciptakan dampak besar pada kecepatan dan kekuatan arus laut, kesehatan perikanan pesisir, dan cuaca lokal dari Australia ke Amerika Selatan dan sekitarnya. Perubahan nilai anomali SPL di wilayah Nino menyebabkan hampir setengah dari fenomena tersebut. Dalam penelitian ini, penulis mengusulkan untuk menggunakan model ANN yang *Recurrent Neural Network - Long Short-Term Memory* (RNN-LSTM) untuk memprediksi nilai anomali SPL di masa yang akan datang di wilayah Nino khususnya Nino 3.4. LSTM adalah RNN versi lebih kompleks, yang memperkenalkan mekanisme *forget gate* ke vanilla RNN untuk mencegah masalah *vanishing gradient*. LSTM memiliki kemampuan yang kuat untuk memodelkan hubungan temporal data deret waktu dan dapat menangani masalah *long term dependencies*. Dalam arsitektur, Model RNN-LSTM ini menggunakan 2 *hidden layer* LSTM yang terdiri dari 50 LSTM Neuron di setiap lapisannya. Tanh digunakan sebagai Activation function. Mean Square Error digunakan sebagai *Loss Function*. Adam dan Adagrad Optimizer digunakan sebagai optimisasi. Riset ini mengeksplorasi pengaturan optimal dari arsitektur ini dengan eksperimen dan melihat *Root mean Square Error* dari wilayah Nino 3.4 dengan membandingkan dengan nilai anomali yang telah terjadi untuk mengkonfirmasi keefektifan metode yang diusulkan.





RSITAS BRAI

(Halaman sengaja dikosongkan)



**Kata kunci:** Prediksi, Nino, Nino 3.4, Suhu Permukaan Laut, *Sea Surface Temperature*, *Recurrent Neural Network*, *Long Short-Term Memory*





RSITAS BRAI

(Halaman sengaja dikosongkan)







# **PREDICTING ANOMALY VALUE OF SEA SURFACE TEMPERATURE IN NINO 3.4 AREA USING RECURRENT NEURAL NETWORK LONG SHORT-TERM MEMORY METHOD**

## **ABSTRACT**

Predicting the anomaly sea surface temperature (SST) value in Nino region has been done by many Institution, because of the phenomenon El Niño Southern Oscillation (ENSO) creates massive impact on the speed and strength of ocean currents, the health of coastal fisheries, and local weather from Australia to South America and beyond. The changes of anomaly SST value in Nino region is takes almost half the phenomenon. In this research, the authors proposed to use ANN model called Recurrent Neural Network - Long Short-Term Memory (RNN-LSTM) to predict future anomaly SST value in Nino region specifically Nino 3.4. LSTM is a more advance version of recurrent neural network, which introduces forget gate mechanism into vanilla RNN to prevent the vanishing gradient problem. It has strong ability to model the temporal relationship of time series data and can handle the long-term dependency problem. In the architecture, this RNN-LSTM Model used 2 Hidden Layer LSTM consisting of 50 LSTM Neurons in each layer. Tanh was used as the activation function. Mean Square Error was used as the loss function. Adam and Adagrad Optimizer was used as the optimization. This project explore the optimal setting of this architecture by experiments and report the root mean square error of Nino 3.4 region by compared with its actual value to confirm the effectiveness of the proposed method.

**Keywords:** Prediction, Nino- Region, Nino 3.4, Sea Surface Temperature, Recurrent Neural Network, Long Short-Term Memory



RSITAS BRAI

(Halaman sengaja dikosongkan)



## KATA PENGANTAR

Bismillahirrahmanirrahim, Alhamdulillahillobb 'alamin. Segala puji dan syukur kepada Allah Subhanahu wa Ta'ala, Tuhan semesta alam yang telah mencurahkan karunia dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi ini dapat tersusun dengan baik.

Terimakasih saya ucapkan kepada kedua Orang tua tercinta, Kakak dan Adik yang sudah memberi dukungan dan doanya, Dr. Eng. Agus Naba, S.Si., MT. selaku dosen pembimbing I dan Dr.rer.nat. Abdurro'uf, S.Si. M.Si. selaku dosen pembimbing II yang telah memberikan pengarahan serta masukan dalam penyusunan skripsi ini, staff bagian analisa BMKG Stasiun Klimatologi Karangploso Kab. Malang yang telah membantu mengarahkan dalam analisa penelitian ini, serta teman-teman sekalian yang telah membantu penulis selama proses penyelesaian skripsi ini, baik secara moril ataupun materil sehingga skripsi yang berjudul **"PREDIKSI NILAI ANOMALI SUHU PERMUKAAN LAUT PADA AREA NINO 3.4 MENGGUNAKAN METODE RECURRENT NEURAL NETWORK LONG SHORT-TERM MEMORY"** sebagai salah satu persyaratan kelulusan untuk memperoleh gelar Sarjana Sains dalam bidang Fisika. Penulis menyadari bahwa dalam penyusunan skripsi ini masih terdapat banyak kekurangan, untuk itu penulis sangat menerima kritik dan saran yang bersifat konstruktif untuk menyempurnakan skripsi ini.

Semoga karya tulis ini dapat memberi manfaat serta inspirasi bagi penulis juga pembacanya.

Malang, 24 Juni 2019

Penulis





RSITAS BRAI

(Halaman sengaja dikosongkan)







## DAFTAR ISI

LEMBAR PERNYATAAN .....	ii
-------------------------	----

ABSTRAK .....	iv
---------------	----

ABSTRACT .....	viii
----------------	------

KATA PENGANTAR .....	x
----------------------	---

DAFTAR ISI .....	xii
------------------	-----

DAFTAR GAMBAR .....	xvi
---------------------	-----

DAFTAR TABEL .....	xxii
--------------------	------

DAFTAR LAMPIRAN .....	xxiv
-----------------------	------

BAB I PENDAHULUAN .....	1
-------------------------	---

1.1 Latar Belakang .....	1
--------------------------	---

1.2 Rumusan Masalah .....	4
---------------------------	---

1.3 Batasan Masalah .....	5
---------------------------	---

1.4 Tujuan Penelitian .....	5
-----------------------------	---

1.5 Manfaat Penelitian .....	6
------------------------------	---

BAB II TINJAUAN PUSTAKA .....	7
-------------------------------	---

2.1 Suhu Permukaan Laut .....	7
-------------------------------	---

2.2 Fluks Panas Laut .....	7
----------------------------	---

2.3 Istilah Dalam Fluks Panas .....	8
-------------------------------------	---

2.3.1 Insolasi .....	9
----------------------	---



2.3.2 Net Radiasi Infra Merah .....	10
2.3.3 Latensi Fluks Panas .....	10
2.3.4 Sensible heat flux .....	11
2.4 El Nino Southern Oscillation (ENSO) .....	11
2.5 Artificial Intelligence .....	12
2.6 Pengujian Sistem Kecerdasan Buatan .....	13
2.6 Machine Learning .....	14
2.7 <i>Supervised Learning</i> .....	16
2.8 Artificial Neural Networks .....	17
2.9 Recurrent Neural Network .....	19
2.10 Jaringan Long Short-Term Memory .....	20
2.11 <i>R Programming Language</i> .....	21
2.12 TensorFlow .....	21
2.13 Keras .....	22
BAB III METODE PENELITIAN .....	23
3.1 Lokasi dan Waktu .....	23
3.2 Alat dan Bahan .....	23
3.3 Tahapan Penelitian .....	23
3.3.1 Persiapan Perangkat Lunak .....	23
3.3.2 Pengambilan Data .....	25
3.3.3 Pengolahan Data .....	28



3.3.4 Pembuatan Model Neural Network .....	29
3.3.5 Pelatihan Neural Network .....	30
3.3.6 Pengujian Neural Network .....	31
<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	<b>35</b>
4.1 Prediksi Model dengan Variasi Panjang Tahun Input .....	35
4.2 Prediksi Model untuk Variasi Panjang Waktu .....	38
4.3 Prediksi Model untuk Variasi Tahun .....	40
4.4 Prediksi Model Saat Kondisi Ekstrim .....	42
4.5 Prediksi Model Pada Tahun 2019 .....	46
<b>BAB V PENUTUP .....</b>	<b>49</b>
5.1 Kesimpulan .....	49
5.2 Saran .....	50
<b>Daftar Pustaka .....</b>	<b>51</b>



RSITAS BRAI

(Halaman sengaja dikosongkan)





## DAFTAR GAMBAR

Gambar 2. 1 Oceanic Nino Index (ONI) dengan fase suhu permukaan laut abnormal di Samudera Pasifik tropis.....	12
Gambar 2. 2 Perbandingan kerangka kerja AI, Machine Learning, dan Deep Learning.....	15
Gambar 2. 3 Struktur layer metode Deep Learning.....	16
Gambar 2. 4 Alur kerja Supervised Learning.....	16
Gambar 2. 5 Alur kerja Supervised Learning.....	18
Gambar 2. 6 Contoh skema sederhana topologi FNN & RNN.....	18
Gambar 2. 7 Alur kerja matematis dari topologi RNN.....	19
Gambar 2. 8 Unit layer RNN sederhana (input, hidden, output).....	20
Gambar 2. 9 Unit layer RNN-LSTM (input, hidden/sel memori, output).....	20
Gambar 3. 1 Install Rstudio IDE.....	24
Gambar 3. 2 Struktur data Nino dalam bentuk matriks pada situs NOAA .....	26
Gambar 3.3 Oceanic Nino Index (ONI) dengan indikasi fase anomali suhu permukaan laut; waktu yang dilingkari merupakan waktu yang akan diprediksi oleh model.....	33
Gambar 4. 1 Grafik tren fungsi optimasi Adam dan Adagrad prediksi dengan variasi tahun input.....	36
Gambar 4. 2 Grafik prediksi anomali SPL tahun 2018 dengan input sebanyak 27 tahun menggunakan fungsi optimasi Adagrad sebelum dimajukan 1 bulan .....	37
Gambar 4.3 Grafik prediksi anomali SPL tahun 2018 dengan input sebanyak 27 tahun menggunakan fungsi optimasi Adagrad setelah dimajukan 1 bulan .....	38
Gambar 4. 4 Plot RMSE pada tiga model terbaik untuk panjang bulan yang berbeda .....	40
Gambar 4. 5 Plot RMSE pada tiga model terbaik untuk tahun yang berbeda-beda .....	42

Gambar 4. 6 Grafik prediksi anomali SPL pada kondisi El Nino ekstrim tahun 2015-2016 menggunakan model dengan fungsi optimasi Adam .....	44
Gambar 4. 7 Grafik prediksi anomali SPL pada kondisi La Nina ekstrim tahun 2010-2011 menggunakan model dengan fungsi optimasi Adam .....	45
Gambar 4. 8 Grafik prediksi anomali SPL pada kondisi El Nino ekstrim tahun 2015-2016 menggunakan model dengan fungsi optimasi Adagrad .....	45
Gambar 4. 9 Grafik prediksi anomali SPL pada kondisi La Nina ekstrim tahun 2010-2011 menggunakan model dengan fungsi optimasi Adagrad .....	46
Gambar 4. 10 Plot/grafik prediksi SPL pada tahun 2019 dengan tiga model terbaik dari fungsi optimasi Adam dan Adagrad .....	47
Gambar A.1. 1Prediksi 2018 dengan 31 tahun (Adagrad) .....	53
Gambar A.1. 2 Prediksi 2018 dengan 30 tahun (Adagrad) .....	53
Gambar A.1. 3 Prediksi 2018 dengan 29 tahun (Adagrad) .....	54
Gambar A.1. 4 Prediksi 2018 dengan 28 tahun (Adagrad) .....	54
Gambar A.1. 5 Prediksi 2018 dengan 27 tahun (Adagrad) .....	55
Gambar A.1. 6 Prediksi 2018 dengan 26 tahun (Adagrad) .....	55
Gambar A.1. 7 Prediksi 2018 dengan 25 tahun (Adagrad) .....	56
Gambar A.1. 8 Prediksi 2018 dengan 24 tahun (Adagrad) .....	56
Gambar A.1. 9 Prediksi 2018 dengan 23 tahun (Adagrad) .....	57
Gambar A.1. 10 Prediksi 2018 dengan 22 tahun (Adagrad) .....	57
Gambar A.1. 11 Prediksi 2018 dengan 21 tahun (Adagrad) .....	58
Gambar A.1. 12 Prediksi 2018 dengan 20 tahun (Adagrad) .....	58
Gambar A.1. 13 Prediksi 2018 dengan 19 tahun (Adagrad) .....	59
Gambar A.1. 14 Prediksi 2018 dengan 18 tahun (Adagrad) .....	59
Gambar A.1. 15 Prediksi 2018 dengan 17 tahun (Adagrad) .....	60
Gambar A.1. 16 Prediksi 2018 dengan 16 tahun (Adagrad) .....	60
Gambar A.1. 17 Prediksi 2018 dengan 31 tahun (Adam) .....	61



Gambar A.1. 18 Prediksi 2018 dengan 30 tahun (Adam) .....	61
Gambar A.1. 19 Prediksi 2018 dengan 29 tahun (Adam) .....	62
Gambar A.1. 20 Prediksi 2018 dengan 28 tahun (Adam) .....	62
Gambar A.1. 21 Prediksi 2018 dengan 27 tahun (Adam) .....	63
Gambar A.1. 22 Prediksi 2018 dengan 26 tahun (Adam) .....	63
Gambar A.1. 23 Prediksi 2018 dengan 25 tahun (Adam) .....	64
Gambar A.1. 24 Prediksi 2018 dengan 24 tahun (Adam) .....	64
Gambar A.1. 25 Prediksi 2018 dengan 23 tahun (Adam) .....	65
Gambar A.1. 26 Prediksi 2018 dengan 22 tahun (Adam) .....	65
Gambar A.1. 27 Prediksi 2018 dengan 21 tahun (Adam) .....	66
Gambar A.1. 28 Prediksi 2018 dengan 20 tahun (Adam) .....	66
Gambar A.1. 29 Prediksi 2018 dengan 19 tahun (Adam) .....	67
Gambar A.1. 30 Prediksi 2018 dengan 18 tahun (Adam) .....	67
Gambar A.1. 31 Prediksi 2018 dengan 17 tahun (Adam) .....	68
Gambar A.1. 32 Prediksi 2018 dengan 16 tahun (Adam) .....	68
Gambar A.2. 1 Prediksi Juli - Desember 2018 dengan input 29 tahun (Adagrad) .....	69
Gambar A.2. 2 Prediksi April - Desember 2018 dengan input 29 tahun (Adagrad) .....	69
Gambar A.2. 3 Prediksi Juli - Desember 2018 dengan input 28 tahun (Adagrad) .....	70
Gambar A.2. 4 Prediksi April - Desember 2018 dengan input 28 tahun (Adagrad) .....	70
Gambar A.2. 5 Prediksi Juli - Desember 2018 dengan input 27 tahun (Adagrad) .....	71
Gambar A.2. 6 Prediksi April - Desember 2018 dengan input 27 tahun (Adagrad) .....	71
Gambar A.2. 7 Prediksi Juli - Desember 2018 dengan input 25 tahun (Adam) .....	72
Gambar A.2. 8 Prediksi April - Desember 2018 dengan input 25 tahun (Adam) .....	72





Gambar A.2. 9 Prediksi Juli - Desember 2018 dengan input 26 tahun (Adam) .....	73
Gambar A.2. 10 Prediksi April - Desember 2018 dengan input 26 tahun (Adam) .....	73
Gambar A.2. 11 Prediksi Juli - Desember 2018 dengan input 18 tahun (Adam) .....	74
Gambar A.2. 12 Prediksi April - Desember 2018 dengan input 18 tahun (Adam) .....	74
Gambar A.3. 1 Prediksi tahun 2017 dengan input 29 tahun (Adagrad).....	75
Gambar A.3. 2 Prediksi tahun 2014 dengan input 29 tahun (Adagrad) .....	75
Gambar A.3. 3 Prediksi tahun 2017 dengan input 28 tahun (Adagrad) .....	76
Gambar A.3. 4 Prediksi tahun 2014 dengan input 27 tahun (Adagrad) .....	76
Gambar A.3. 5 Prediksi tahun 2017 dengan input 27 tahun (Adagrad) .....	77
Gambar A.3. 6 Prediksi tahun 2014 dengan input 27 tahun (Adagrad) .....	77
Gambar A.3. 7 6 Prediksi tahun 2017 dengan input 26 tahun (Adam) .....	78
Gambar A.3. 8 Prediksi tahun 2014 dengan input 26 tahun (Adam).....	78
Gambar A.3. 9 Prediksi tahun 2017 dengan input 25 tahun (Adam).....	79
Gambar A.3. 10 Prediksi tahun 2014 dengan input 25 tahun (Adam) .....	79
Gambar A.3. 11 Prediksi tahun 2017 dengan input 18 tahun (Adam) .....	80
Gambar A.3. 12 Prediksi tahun 2014 dengan input 18 tahun (Adam) .....	80





Gambar A.4. 1 La Nina input 29 tahun prediksi 2010-2011 (Adagrad)	81
Gambar A.4. 2 La Nina input 28 tahun prediksi 2010-2011 (Adagrad)	81
Gambar A.4. 3 La Nina input 27 tahun prediksi 2010-2011 (Adagrad)	82
Gambar A.4. 4 El Nino input 29 tahun prediksi 2015-2016 (Adagrad)	82
Gambar A.4. 5 El Nino input 28 tahun prediksi 2015-2016 (Adagrad)	83
Gambar A.4. 6 El Nino input 27 tahun prediksi 2015-2016 (Adagrad)	83
Gambar A.4. 7 La Nina input 26 tahun prediksi 2010-2011 (Adam)	84
Gambar A.4. 8 La Nina input 25 tahun prediksi 2010-2011 (Adam)	84
Gambar A.4. 9 La Nina input 18 tahun prediksi 2010-2011 (Adam)	85
Gambar A.4. 10 El Nino input 26 tahun prediksi 2015-2016 (Adam)	85
Gambar A.4. 11 El Nino input 25 tahun prediksi 2015-2016 (Adam)	86
Gambar A.4. 12 El Nino input 18 tahun prediksi 2015-2016 (Adam)	86



RSITAS BRAI

(Halaman sengaja dikosongkan)



## DAFTAR TABEL

Tabel 3. 1 Struktur data frame Nino 3, 4, & 3.4 diubah menjadi 2 kolom .....	27
Tabel 3. 2 Struktur dataframe Nino 3, 4, & 3.4 disatukan kedalam satu file .....	27
Tabel 3.3 Sampel Data Dibagi Training set dan Testing set yang telah di normalisasi .....	29
Tabel 3. 4 Pengujian model dengan data tahun input yang berbeda-beda .....	31
Tabel 3. 5 Pengujian kedua dengan panjang bulan yang berbeda-beda .....	32
Tabel 3. 6 Pengujian ketiga dengan tahun yang berbeda-beda.....	33
Tabel 3. 7 Pengujian keempat ketika daera Nino berada pada kondisi Ekstrim .....	33
Tabel 4. 1 Prediksi dengan input yang berbeda .....	35
Tabel 4. 2 Model dengan performa terbaik prediksi output untuk 6, 9 dan 12 bulan menggunakan fungsi optimasi Adam .....	39
Tabel 4. 3 Model dengan performa terbaik prediksi output untuk 6, 9 dan 12 bulan menggunakan fungsi optimasi Adagrad .....	39
Tabel 4. 5 Model dengan performa terbaik prediksi output dengan tahun berbeda menggunakan fungsi optimasi Adam .....	41
Tabel 4. 6 Model dengan performa terbaik prediksi output dengan tahun berbeda menggunakan fungsi optimasi Adagrad .....	41
Tabel 4. 7 Model dengan performa terbaik prediksi output pada kondisi ekstrim menggunakan fungsi optimasi Adam .....	43
Tabel 4. 8 Model dengan performa terbaik prediksi output pada kondisi ekstrim menggunakan fungsi optimasi Adagrad .....	43





RSITAS BRA

(Halaman sengaja dikosongkan)







## DAFTAR LAMPIRAN

LAMPIRAN A DATA HASIL PENELITIAN ..... 54

LAMPIRAN B KODE PROGRAM ..... 88





RSITAS BRAI

(Halaman sengaja dikosongkan)



## BAB I PENDAHULUAN

### 1.1 Latar Belakang

Menyelimuti 70% dari permukaan Bumi, keberadaan laut memberikan dampak besar baik dari segi sosial ataupun lingkungan. Kita bergantung pada laut untuk banyak hal baik dalam kebutuhan pangan, transportasi laut, rekreasi, mineral, dan energi. Ketika arus lautan berubah, mereka akan menyebabkan perubahan pola cuaca secara global dan dapat memberi dampak kekeringan, banjir, hingga badai sekalipun. Meski demikian, informasi kita akan lautan masih terbatas (Greely, 1998). Kapal, garis pantai, dan pulau-pulau menyediakan sampel observasi untuk studi pembelajaran, akan tetapi itupun hanya bagian kecil dari luasnya permukaan laut di Bumi. Dibutuhkan tempat yang dapat memberikan cakupan lebih baik tentang lautan.

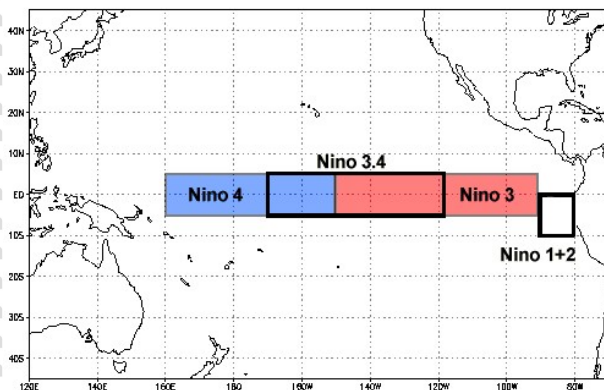
Beruntungnya, luar angkasa dapat memberikan tempat ideal tersebut. Satelit di luar angkasa menjadi sebuah instrumen yang dapat memberikan gambaran luas akan lautan. Satelit yang mengelilingi bumi dapat memberikan data survey dari seluruh lautan dalam waktu kurang dari dua jam (American Meteorological Society, 2012). Satelit-satelit tersebut dapat mengobservasi awan-awan untuk mempelajari cuaca, ataupun permukaan laut (ketika tidak pada cuaca berawan) untuk mengukur suhu permukaan laut, serta tinggi dan arah gelombang (Greely, 1998).

Suhu permukaan laut (SPL), merupakan parameter penting dalam keseimbangan energi di permukaan bumi dan interaksi atmosfer, karena itu SPL memberikan pengaruh yang signifikan pada iklim global dan bagi sistem biologis. Dalam upaya mempelajari aktivitas SPL, manusia menggunakan satelit untuk mengobservasi melalui data



yang diperoleh. Satelit NOAA (National Oceanic and Atmospheric Administration) merupakan salah satu satelit yang digunakan untuk mengobservasi aktivitas SPL.

Dalam dunia klimatologi terdapat beberapa lokasi permukaan laut yang diobservasi suhunya untuk beberapa keperluan penting, salah satu lokasi yang menjadi observasi utama adalah daerah Nino atau lebih spesifiknya lagi Nino 3.4 yang terletak pada Samudra Pasifik di garis khatulistiwa/ekuatorial, timur Papua Nugini dan barat Amerika Selatan seperti pada gambar 1.1. Daerah Nino diobservasi karena suatu fenomena yaitu *El Niño-Southern Oscillation* (ENSO). ENSO adalah pola iklim berulang yang melibatkan perubahan suhu air di Samudera Pasifik Tropis tengah dan timur. Akibat dari dinamika osilasi suhu yang disebabkan oleh ENSO, fenomena ini memberikan dampak seperti pada temperatur lautan, kecepatan dan kekuatan arus laut, kesehatan ikan di pesisir, serta cuaca lokal dari Benua Australia hingga Amerika Selatan. Untuk mengantisipasi akan fenomena tersebut menggunakan peneliti mengobservasi anomali suhu permukaan laut pada daerah Nino untuk memprediksi akan terjadinya perubahan iklim atau dampak lingkungan yang disebabkan.



Gambar 1.1 lokasi Nino dan pembagian area Nino 1+2, 3, 3.4, dan 4



Dalam upaya untuk mengantisipasi akan dampak daerah tersebut, para ilmuwan perlu membuat model dari suhu permukaan laut pada area Nino 3.4 agar dapat dipelajari dan diawasi. Secara umum terdapat dua metode untuk menghasilkan model, pertama dengan menggunakan model numerik, yang dibuat berdasarkan aktivitas fisis suatu fenomena dan yang kedua dengan *data-driven model*, yang dibuat berdasarkan pola statistik dari data yang ada.

Skripsi ini fokus pada pembuatan *data-driven model*. Terdapat beberapa metode untuk membuat *data-driven model*, namun penulis menggunakan metode *machine learning*, hal ini dikarenakan *machine learning* telah beberapa kali memberikan hasil yang baik dalam hal memprediksi dan memberikan wawasan dari data yang diolahnya (Adebiyi, 2014). *Machine learning* adalah cabang dari kecerdasan buatan, atau lebih spesifik lagi yaitu ilmu komputer, yang berarti erat hubungannya dengan ilmu sistem dan algoritma yang dapat mempelajari sekumpulan data dan memperoleh informasi dari sekumpulan data yang telah dipelajarinya.

Karena data yang diperoleh dari satelit NOAA adalah serangkaian nilai data dengan orde indeks waktu atau biasa disebut sebagai data *time series*, digunakan metode *Long-short term memory* (LSTM) dalam pengolahannya. LSTM adalah arsitektur *Recurrent Neural Network* (RNN) yang mempunyai koneksi siklik dari waktu ke waktu. Aktivasi dari setiap iterasinya akan disimpan dalam keadaan internal dari jaringan untuk menetapkan memori sementara. Kapabilitas ini membuat metode *machine learning* dengan arsitektur RNN cocok untuk pekerjaan model seri dengan input data multivariat seperti memprediksi data *time series*. Telah dilakukan penelitian menggunakan model RNN-LSTM dengan fungsi optimasi Adagrad untuk memprediksi SPL pada laut Bohai yang terletak di dekat laut Kuning dan teluk Korea di pantai Timur Laut dan Cina Utara (Qin Zhang, 2017). Pada penelitian tersebut penenliti menggunakan *basic*

LSTM *blocks* dengan 31 tahun (1981-2012) data sebagai pembelajaran modelnya untuk memprediksi nilai SPL pada laut Bohai selama kedepan 3 tahun (2013-2015). Hasil yang didapatkan bahwa LSTM memberikan hasil yang baik dalam memprediksi nilai suhu permukaan laut.

Pada penelitiannya Qin Zhang menggunakan fungsi optimasi Adagrad yang merupakan fungsi optimasi gradien stokastik yang dikembangkan untuk mengoptimasi data-data dengan jumlah yang lebih besar kedalam suatu *data-driven* model. Namun dilain sisi para praktisi *machine learning* dalam industri lebih umum untuk menggunakan fungsi optimasi Adam, dikarenakan fungsi optimasi adam merupakan fungsi optimasi yang dikembangkan dari mengkombinasikan antara fungsi optimasi Adagrad dan Rmsprop (Kingma, 2015).

Berdasarkan penelitian prediksi nilai suhu permukaan laut yang dilakukan oleh Qin Zhing dan rekan-rekannya di laut Bohai, penulis berusaha untuk membuat sistem prakiraan baru yang dapat memprediksi nilai suhu permukaan laut beberapa tahun ke depan di area Nino 3.4 menggunakan model RNN Long Short-Term Memory yaitu sistem jaringan syaraf buatan yang didesain khusus untuk menangani permasalahan deret waktu dalam jangka waktu yang panjang dengan fungsi optimasi Adam dan Adagrad.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan, rumusan masalah dalam penelitian ini adalah:

1. Bagaimana kemampuan model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad ketika memprediksi nilai anomali suhu permukaan laut dengan data input yang semakin banyak?

2. Bagaimana kemampuan model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad ketika memprediksi nilai anomali suhu permukaan laut pada 6, 9 dan 12 bulan kedepan?
3. Bagaimana kemampuan model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad ketika memprediksi nilai anomali suhu permukaan laut pada tahun yang berbeda-beda?
4. Bagaimana kemampuan model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad ketika memprediksi pada kondisi ekstrim pada tahun 2010-2011 dan 2015-2016?

### 1.3 Batasan Masalah

Ruang lingkup dalam penelitian ini dibatasi oleh beberapa hal sebagai berikut:

1. Penentuan prediksi nilai suhu permukaan laut menggunakan data bulanan suhu permukaan laut pada tahun 1981 sampai 2018.
2. Lokasi suhu permukaan laut yang diamati adalah daerah Nino 3, Nino 3.4, dan Nino 4.
3. Penentuan prediksi suhu permukaan laut tidak melibatkan faktor fisis yang mempengaruhi suhu permukaan laut (seperti Kelembaban Udara, Bintik Matahari, dan Temperatur Udara).

### 1.4 Tujuan Penelitian

Tujuan penelitian yang dilakukan adalah:

1. Mengetahui kemampuan model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad dalam prediksi ketika menggunakan data input yang semakin banyak.
2. Mengetahui kemampuan model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad ketika memprediksi nilai anomali suhu permukaan laut untuk 6, 9, dan 12 bulan kedepan.
3. Mengetahui kemampuan model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad ketika memprediksi nilai anomali suhu permukaan laut pada tahun yang berbeda-beda.



4. Mengetahui kemampuan model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad pada kondisi ekstrim di tahun 2010-2011 dan 2015-2016.

### 1.5 Manfaat Penelitian

Manfaat yang didapatkan pada penelitian ini adalah:

1. Bagi Instansi Pemerintah (BMKG): Hasil model RNN-LSTM akan diserahkan kepada BMKG untuk digunakan sebagai alat bantu analisis prediksi suhu permukaan laut area Nino 3.4.
2. Bagi peneliti di bidang oseanografi dan klimatologi: Hasil dari model ini akan membantu peneliti bidang oseanografi, iklim, dan cuaca dalam menganalisa prediksi nilai suhu permukaan laut di waktu yang akan datang.





## BAB II TINJAUAN PUSTAKA

### 2.1 Suhu Permukaan Laut

Suhu permukaan laut (SPL) adalah suhu air yang berada dekat dengan atau pada permukaan laut. Definisi tepat untuk menggambarkan kedalaman/ketebalan permukaan laut bervariasi tergantung dengan metode pengukurannya mulai dari 1 milimeter sampai dengan 20 meter dibawah permukaan. Udara pada atmosfer Bumi sangat dipengaruhi oleh suhu permukaan laut yang berjarak dekat dengan pesisir.

SPL ditentukan oleh dua hal yaitu, proses atmosferik dan oseanik (Deser, 2009). Jika dilihat dari sisi atmosferik, SPL dipengaruhi oleh faktor-faktor dominan yaitu, kecepatan angin, temperatur udara, kemendungan, dan kelembaban, dalam proses pertukaran energi pada permukaan laut. Sementara dari sisi oseanik, transportasi panas dilakukan oleh arus, batas kedalaman lapisan yang mempengaruhi SPL, dan pencampuran vertikal —pergerakan ke atas dan ke bawah dari air atau udara yang terjadi akibat adanya temperatur gradien (perbedaan temperatur pada lapisan fluida).

### 2.2 Fluks Panas Laut

Perubahan energi yang disimpan oleh laut bagian atas merupakan hasil dari tidak seimbangnya masukan dan keluaran dari panas yang melewati permukaan laut. Perpindahan panas melalui atau melintasi permukaan disebut sebagai fluks panas (*heat flux*). Fluks dari panas dan air juga dapat mengubah densitas dari permukaan air, serta memengaruhi daya apung mereka. Sebagai hasilnya, jumlah keseluruhan dari fluks air dan panas seringkali disebut sebagai fluks daya apung (*bouyancy flux*). Secara matematis, fluks panas (*heat flux*) untuk lapisan campur (*mixed layer*) laut bagian atas dapat ditulis sebagai berikut:

$$\frac{\delta T}{\delta t} = \frac{Q_{net}}{(\rho C_p H)} + (\vec{U}_{geo} + \vec{U}_{ek}) \cdot \vec{\nabla} T + \frac{(W_e + W_{ek})(T + T_b)}{H}, \quad (1)$$

dimana  $\rho$  adalah densitas air laut,  $C_p$  adalah kalor jenis dari air laut,  $H$  adalah kedalaman *mixed layer*,  $T$  adalah temperatur *mixed layer* (sama dengan nilai SPL),  $Q_{net}$  adalah net fluks energi permukaan,  $\vec{U}_{geo}$  adalah kecepatan arus geostropik,  $\vec{U}_{ek}$  adalah kecepatan arus Ekman,  $W_e$  adalah tingkat *vertical entrainment*,  $W_{ek}$  adalah kecepatan pompa Ekman, dan  $T_b$  adalah temperatur air pada ke dalam yang dimasukan kedalam *mixed layer*.

Fluks energi pada lapisan dalam biasanya memiliki fluks lebih kecil dibanding fluks di permukaan. Total dari energi fluks yang masuk dan keluar dari lautan pasti bernilai nol, jika tidak, lautan secara menyeluruh akan memanaskan atau mendingin (Stewart, 2008). Total dari fluks panas permukaan laut ( $Q_{net}$ ) yang masuk atau keluar dari volume air biasa disebut juga sebagai perimbangan bahang (*heat budget*). Jika persamaan (1) disederhanakan maka  $Q_{net}$  dapat di definisikan sebagai,

$$Q_{net} = Q_{sb} + Q_{lb} + Q_{sw} + Q_{lw}, \quad (2)$$

dimana bagian dari fluks total yang terdapat pada permukaan laut yaitu,

1. Insolasi  $Q_{sw}$ , fluks dari energi matahari yang masuk ke laut;
2. Net Radiasi Infra Merah (*Net Infrared Radiation*)  $Q_{lw}$ , net radiasi fluks inframerah dari laut;
3. *Sensible Heat Flux*  $Q_{sb}$ , fluks panas yang keluar dari laut karena adanya konduksi;
4. Latensi Fluks Panas  $Q_{lb}$ , energi fluks yang terbawa oleh air yang menguap;

### 2.3 Istilah Dalam Fluks Panas

Terdapat empat faktor yang mempengaruhi fluks panas total permukaan laut ( $Q_{net}$ ). Masing-masing faktor memberikan dampak yang berbeda-beda, sebagian faktor memberikan efek yang dominan

pada interaksi panas permukaan laut dan sebagian lagi tidak terlalu. Efek-efek tersebut dipengaruhi oleh berbagai macam faktor, berikut merupakan gambaran serta penjelasan akan faktor yang mempengaruhi ditinjau dari masing-masing komponen fluks panas yang berpengaruh akan fluks panas total permukaan laut.

### 2.3.1 Insolasi

Faktor Insolasi, datangnya surya —radiasi matahari— ditentukan terutama oleh garis lintang, musim, waktu hari, dan kemendungan. Daerah kutub terpapar panas lebih sedikit oleh faktor insolasi dibanding daerah tropis, begitu juga daerah musim dingin yang terpapar panas lebih sedikit dibanding daerah yang sedang terkena musim panas, dan begitu juga hari-hari yang mendung mendapatkan paparan matahari lebih sedikit dibanding hari-hari cerah.

Berikut ini merupakan faktor yang mempengaruhi Insolasi:

1. Tinggi matahari diatas ufuk (*horizon*), yang bergantung pada garis lintang, musim, dan waktu hari.
2. Panjang waktu di siang hari, yang bergantung pada garis lintang dan musim.
3. Daerah melintang dari permukaan yang menyerap sinar matahari, yang bergantung pada tinggi matahari diatas ufuk.
4. Atenuasi, bergantung pada i) Awan, yang menyerap dan menghamburkan radiasi; ii) Panjang jalur atmosfer yang dilalui, yang bervariasi selagi sudut matahari saat diatas garis ufuk; iii) Gas molekul-molekul, yang menyerap radiasi dalam pita-pita tertentu.  $H_2O$ ,  $O_3$ , dan  $CO_2$  sangat penting dalam proses ini; iv) Aerosol, yang menghamburkan dan menyerap radiasi. Baik itu Aerosol laut atau vulkanik; v) Debu, yang menghamburkan radiasi, terutama debu sahara diatas atlantik.
5. Reflektivitas dari permukaan, yang bergantung pada sudut elevasi sinar matahari dan kekasaran permukaan laut.



Inklinasi radiasi matahari dan kemendungan merupakan faktor yang dominan. Sementara penyerapan oleh ozon, uap air, aerosol, dan debu jauh lebih lemah.

### 2.3.2 Net Radiasi Infra Merah

Faktor net radiasi infra merah, permukaan laut mengemisikan radiasi layaknya benda hitam yang mempunyai temperatur sama seperti air laut, yang berarti sekitar 290K. distribusi radiasi sesuai dengan fungsi panjang gelombang yang diberikan oleh persamaan Planck. Berikut ini merupakan faktor yang mempengaruhi net radiasi infra merah:

1. Ketebalan awan. Semakin tebal awannya, semakin sedikit panas yang keluar ke ruang.
2. Ketinggian awan, yang menentukan temperatur pada saat awan meradiasikan panas kembali ke lautan.
3. Komposisi uap air pada atmosfer. Semakin lembab atmosfernya, maka semakin sedikit panas yang keluar.
4. Temperatur air. Semakin panas air akan semakin panas radiasi yang diemisikan.
5. Es dan lapisan es. Es mengeluarkan emisi seperti benda hitam, tapi ia lebih cepat mendingin dari pada laut terbuka.

Sementara Lautan yang tertutup es terinsulasi dari atmosfer.

### 2.3.3 Latensi Fluks Panas

Faktor latensi fluks panas, latensi fluks panas dipengaruhi terutama oleh kecepatan angin dan kelembaban. Angin tinggi dan udara kering menguap lebih banyak air daripada angin lemah dengan kelembaban relatif mendekati 100%.


### 2.3.4 Sensible heat flux

Faktor *Sensible heat flux*, *sensible heat flux* dipengaruhi oleh kecepatan angin dan perbedaan temperatur air-udara. Angin tinggi dan perbedaan temperatur yang besar menghasilkan fluks panas yang tinggi.

### 2.4 El Nino Southern Oscillation (ENSO)

ENSO muncul di lautan tropis Pasifik dan merupakan sinyal variasi iklim interannual alami terbesar yang memiliki dampak sangat parah pada sistem iklim global. Fenomena ini berganti-ganti antara peristiwa El Niño (La Niña) di laut Pasifik yang membentang dari pantai Peru dan Ekuador ke pusat. Hal ini ditandai dengan tiga rata-rata berturut-turut dari anomali suhu permukaan laut di wilayah Niño 3.4 ( $5^{\circ}\text{S}$  dan  $170^{\circ}\text{W}$  –  $120^{\circ}\text{W}$ ) yang berada di atas ambang  $+0.5^{\circ}\text{C}$  atau  $-0.5^{\circ}\text{C}$  masing-masing Indeks Niño (ONI) adalah indeks standar untuk memantau ENSO.

ENSO memiliki tiga fase: El Nino, La Nino, dan netral. Dan intensitas fase dikategorikan sebagai: El Niño kuat (La Niña), El Niño lemah (La Niña), dan ENSO netral berdasarkan pada sekitar  $1,0^{\circ}\text{C}$  ( $.10$  dari indeks anomali SSTs anomali Niño 3,4. Namun dalam penggambarannya fase tersebut seringkali digambarkan menjadi tiga sampai empat fase yaitu sangat kuat, kuat, moderat/edang, dan lemah seperti pada gambar 2.1.



Gambar 2.1 Oceanic Niño Index (ONI) dengan fase suhu permukaan laut abnormal di Samudera Pasifik tropis

## 2.5 Artificial Intelligence

Pada beberapa tahun belakangan ini perkembangan dalam teknologi kecerdasan buatan berkembang secara eksponensial. Tidak hanya berkembang dalam segi keilmuan saja, namun pengaplikasiannya diberbagai sektor ilmu dan pekerjaan membuatnya menjadi topik panas yang diperbincangkan. Hal-hal tersebut mengakibatkan timbulnya pemahaman serta definisi yang berbeda-beda dari tahun ke tahun. Hal-hal tersebut terkadang dapat membuat bingung beberapa orang karena terlalu banyak definisi dan pemahaman yang muncul.

Definisi yang seringkali digunakan untuk menggambarkan kecerdasan buatan adalah “*imitating intelligent human behaviour*” – “imitasi akan kecerdasan perilaku manusia” (Kok, 2009).

Sudah cukup lama, komunitas kecerdasan buatan mencoba untuk mengimitasi kecerdasan perilaku dengan program-program komputer. Pekerjaan ini tidaklah mudah, dikarenakan program komputer harus bisa melakukan lebih dari satu hal untuk bisa dikatakan *cerdas*.

Cara lain selain mencari penjelasan umum tentang kecerdasan buatan ialah dengan membatasinya dengan definisi *artificially*



*intelligent systems* – sistem kecerdasan buatan (Kok, 2009). Karena dengan begitu akan lebih mudah bagi kita untuk memahaminya. Dengan cara memecahnya menjadi beberapa sistem bagian yang kemudian kita interpretasikan dari masing-masing sistem penyusunnya, seperti bagaimana kita menjelaskan suatu makanan dengan menyebutkan penyusun dari makanan tersebut. Sebagian besar dari penyusun sistem kecerdasan buatan diklasifikasi menjadi empat kategori:

- *Systems that think like humans*—Sistem yang berpikir seperti manusia
- *Systems that act like humans*—Sistem yang beraksi seperti manusia
- *Systems that think rationally*—Sistem yang berpikir secara rasional
- *Systems that act rationally*—Sistem yang beraksi secara rasional

(Kok, 2009)

## 2.6 Pengujian Sistem Kecerdasan Buatan

Untuk menguji benar atau tidak “cerdas”-nya sistem kecerdasan buatan, seorang ahli matematikawan bernama Alan Turing membuat sebuah permainan yang disebut “*the imitation game*”— “Permainan imitasi”, bertujuan untuk menentukan apakah suatu mesin mampu menunjukkan perilaku cerdas yang mirip dengan atau tak dapat dibedakan dengan manusia. “Permainan” tersebut kemudian diketahui sebagai Uji Turing – *Turing Test*.

Uji Turing memberikan beberapa kriteria yang digunakan oleh para ilmuwan untuk menjawab pertanyaan “Bisakah mesin berpikir?”. Untuk bisa “lulus” dalam uji turing komputer (mesin) harus setidaknya memiliki kemampuan berikut (Kok, 2009):

- *Natural language processing*: mesin perlu bisa berkomunikasi dalam bahasa natural seperti bahasa inggris, indonesia, dll.


- *Knowledge representation*: mesin perlu bisa memiliki pengetahuan dan kemampuan untuk menyimpannya disuatu tempat.
- *Automated reasoning*: mesin perlu bisa melakukan proses berpikir berdasarkan pengetahuan yang disimpannya.
- *Machine learning*: mesin perlu bisa belajar dari lingkungan sekitar.

## 2.6 Machine Learning

*Machine learning* merupakan salah satu kemampuan yang diperlukan agar mesin bisa dikata-kan “cerdas”. *Machine learning* adalah bagian dari sistem kecerdasan buatan, dimana mesin perlu bisa belajar dari informasi yang ada dalam lingkungannya. Perihal mesin pada konteks ini dapat dikatakan secara luas adalah mesin yang mampu belajar (*learns*) kapanpun struktur (algoritma), program, atau data (berdasarkan *input* atau respon dari informasi eksternal) berubah-ubah dengan ekspektasi akan memberikan perubahan perilakunya di masa yang akan datang (Nilsson, 1998).

*Machine learning* merupakan bagian penyusun dari ilmu kecerdasan buatan, namun juga secara khusus termasuk dalam cabang ilmu komputer (*computer science*), yang mana berhubungan dengan mempelajari sistem dan algoritma, dimana berhubungan dengan mempelajari sistem dan algoritma dari lingkungannya (data: *input* dan respon informasi eksternal).

Sistem *machine learning* secara eksplisit lebih condong untuk “dilatih” daripada “diprogram”. Mesin disajikan dengan banyak contoh yang relevan dengan tugas (pekerjaan yang diprogram kedalamnya), dan menemukan struktur atau pola statistik dalam contoh-contoh (sekumpulan data) ini yang pada akhirnya memungkinkan sistem untuk membuat aturan untuk mengotomasi tugasnya.




Gambar 2. 2 Perbandingan kerangka kerja AI, Machine Learning, dan Deep Learning

Jika melihat gambar 2.2, di dalam lingkaran AI (*Artificial Intelligence*) terdapat *machine learning* dengan berbagai macam variasi algoritma yang luas, seperti *support vector machines*, *K-means clustering*, *random forests*, dan ratusan lainnya telah dikembangkan selama beberapa dekade terakhir. Sampai pada akhirnya dibuatlah sebuah kerangka kerja baru dari *machine learning* yang diberi nama *deep learning*.

*Deep learning* diketahui juga sebagai *artificial neural networks* (ANNs) karena algoritmanya yang dimodelkan berdasarkan cara otak memproses data meskipun kerangka kerjanya disederhanakan (LeCun, 2015). *Deep learning* merupakan sub bidang dari *machine learning* yang mana representasi pembelajaran data yang diberikannya ditekankan pada pemberian banyaknya *layer* (lapisan) representasi yang bermakna. Dalam *deep learning*, banyaknya *layer* representasi ini belajar melalui model yang disebut sebagai *neural networks*, struktur *literal layers* yang ditumpuk diatas *layer* yang lain seperti pada gambar 2.3.






Gambar 2.3 Struktur layer metode Deep Learning

## 2.7 Supervised Learning

*Supervised learning* merupakan salah satu metodologi dalam *machine learning*. Dalam *supervised learning*, mesin (biasanya program komputer) yang telah diberikan data *input*, data tersebut akan dibagi menjadi dua *set* (kumpulan) data yaitu, *training set* dan *test set*. Perbedaan antara data *training set* dan *test set* berada pada fungsi digunakannya saja. *Supervised learning* sederhananya adalah suatu algoritma pembelajaran dari contoh-contoh seperti pada gambar 2.4. Hal ini dilakukan untuk mesin dapat “belajar” dari contoh data yang telah diberi label pada data *training set* agar ia dapat mengidentifikasi contoh data yang tidak memiliki label pada data *test set* dengan tingkat akurasi setinggi mungkin.



Gambar 2.4 Alur kerja Supervised Learning


Tujuan dari algoritma tersebut adalah untuk mengembangkan aturan, program, atau prosedur yang dapat mengklasifikasikan contoh baru

pada data *test set*— dengan menganalisa contoh-contoh berlabel yang telah diberikan pada mesin. *Output* dari *supervised learning* adalah untuk menciptakan model dengan tingkat akurasi yang tinggi diperoleh dari hasil “pembelajarannya”.

## 2.8 Artificial Neural Networks


Manusia diketahui sebagai makhluk yang cerdas bukan karena otaknya yang besar, akan tetapi dikarenakan 86 miliar neuron yang dimilikinya (Herculano-Houzel, 2016). Dibandingkan dengan hewan lainnya manusia jauh lebih cerdas dan banyak akal nya, dengan jumlah neuron tersebut manusia dapat berbahasa, bertani, berkooperasi, dsb. Begitu juga mesin, untuk mesin dapat melakukan proses pembelajaran ia perlu memiliki neuron atau lebih tepatnya *artificial neuron* untuk membantunya memperoleh pengetahuan. Satu *Artificial neuron* tidak akan membantu banyak bahkan hampir tidak berguna untuk menyelesaikan masalah. Namun jika kita mengkombinasikan dua atau lebih *artificial neuron* kita akan mendapatkan apa yang disebut sebagai *artificial neural network* (ANNs) yang mampu menyelesaikan masalah kompleks di dunia nyata, layaknya otak manusia.

*Artificial Neural Networks* (ANNs) merupakan salah satu bentuk analogi atau imitasi dari sel-sel neuron otak sebagai pemroses informasi (Gerven, 2017). ANN adalah sebuah model matematis jaringan dengan sekumpulan elemen sederhana yang disebut *artificial neurons* (Neuron buatan) yang mendapatkan *input* kemudian terjadi aktivasi—perubahan keadaan internal—berdasarkan *input*-nya, lalu memproduksi *output* bergantung dengan *input* dan aktivasinya. Alur kerja dari ANN dapat dilihat pada gambar 2.5.



Gambar 2. 5 Alur kerja Supervised Learning

*Artificial neuron* yang saling terhubung satu sama lain disebut sebagai topologi atau grafik ANNs. Fakta bahwa neuron dapat terhubung dengan berbagai variasi susunan menghasilkan banyaknya bentuk topologi yang kemudian dibagi menjadi dua kelas dasar yaitu topologi *feed forward* (grafik asiklik) dimana informasi mengalir satu arah dari *input* menuju *output* dan topologi *recurrent* (grafik semi-siklik) dimana beberapa informasinya mengalir tidak pada satu arah saja dari *input* menuju *output* tetapi juga arah sebaliknya seperti pada gambar 2.6.

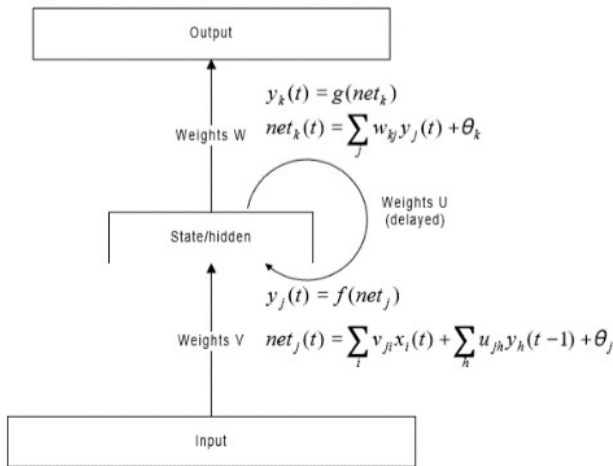


Gambar 2. 6 Contoh skema sederhana topologi FNN & RNN



## 2.9 Recurrent Neural Network

ANNs dengan topologi *recurrent* disebut sebagai *recurrent neural network* (RNN). Dalam kasus topologi seperti gambar (5) informasi tidak lagi ditransmisikan hanya melalui satu arah, tetapi juga ditransmisikan secara terbalik (*backwards*). Hal ini membuat keadaan internal dari jaringan yang mampu menunjukkan perilaku temporal yang dinamis. RNN dapat menggunakan memori internal mereka untuk memproses urutan input apapun seperti pada gambar 2.7 (Krenker, 2011).



Gambar 2. 7 Alur kerja matematis dari topologi RNN

Pada RNN sederhana, secara matematis digambarkan seperti persamaan (4). Dimana tiap lapisan (*layer*) memiliki index variabel sendiri:  $k$  untuk *node output*,  $j$  (dan  $h$ ) untuk *node hidden*, dan  $i$  untuk *node input*.  $v$  adalah bobot dari vektor input  $x$  dan  $u$  adalah lapisan bobot *recurrent* dimana dikombinasikan dengan *state* aktivasi.

$$y_j(t) = f(net_j(t)) \quad (3)$$

$$net_j(t) = \sum_i^m x_i(t)v_{ji} + \sum_h^m y_h(t-1)u_{ji} + \theta_j \quad (4)$$


Output dari jaringan yang dihasilkan baik itu dari feedforward ataupun recurrent ditentukan oleh state dan bobot output,  $w$ ,

$$y_k(t) = g(\text{net}_k(t)) \quad (5)$$


$$\text{net}_k(t) = \sum_j^m y_j(t) w_{kj} + \theta_k \quad (6)$$

## 2.10 Jaringan Long Short-Term Memory

Unit *Long short-term memory* (LSTM) adalah unit bagian dari *recurrent neural network* (RNN) dengan kerangka *deep learning*. *RNN deep learning* yang terhubung dengan LSTM disebut sebagai jaringan *Long short-term memory*. Hal unik dari LSTM adalah komposisi dari penyusunnya yaitu, *input gate*, *output gate*, dan *forget gate*. Penyusun di dalamnya mampu mengingat informasi semanya pada interval waktu tertentu dan tiga *gate* penyusunnya mengatur alir informasi yang masuk dan keluar dari *gate*. *Long short-term memory* (LSTM) *Recurrent Neural Networks* (gambar 2.9) dibangun berdasarkan kerangka *deep learning*.



Gambar 2. 8 Unit layer RNN sederhana (input, hidden, output)



Gambar 2. 9 Unit layer RNN-LSTM (input, hidden/sel memori, output)

Umumnya RNN memiliki memori dalam bentuk bobot (*weight*), dimana bobot itu akan disimpan sampai pada tahap akhir pelatihan suatu model, tapi tidak bukan sel memori. Bobot tersebut akan berubah sepanjang proses pelatihan dilakukan. Jaringan LSTM-pun juga memiliki memori, namun memori jangka pendek yang bersifat aktivasi sementara oleh sel memori—unit LSTM disebut juga sebagai sel memori. kemampuan jaringan LSTM, aktivasi memori sementara menjadi solusi untuk menyelesaikan masalah *long-term dependencies* yang tidak bisa diselesaikan oleh RNN sederhana (gambar 2.8).

*Long short-term memory (LSTM) Recurrent Neural Networks* cocok untuk digunakan dalam pembuatan model yang menggambarkan berbagai masalah kompleks seperti *sequence learning*, *handwriting recognition*, *speech recognition*, atau *time series prediction* (S. Hochreiter, 1997).

## 2.11 R Programming Language

R merupakan bahasa pemrograman tingkat tinggi yang biasa digunakan untuk komputasi statistik dan grafik. R menyediakan berbagai variasi teknik komputasi grafik dan statistik (*linear & nonlinear modelling*, tes statistik klasik, klasifikasi data, *clustering*, dll) (The R Foundation, 2019).

Dikarenakan R adalah software terbuka untuk umum, membuat R memiliki komunitas besar dikalangan komunitas komputasi statistik. banyak *developer* yang membuat *library packages* untuk berbagai macam kebutuhan bidang pekerjaan ataupun penelitian yang dapat di unduh oleh pengguna bahasa R melalui Rstudio—perangkat lunak *Integrated Development Environment (IDE)* khusus untuk R.

## 2.12 TensorFlow

TensorFlow adalah *library* perangkat lunak sumber terbuka untuk kebutuhan komputasi numerik menggunakan aliran data grafik. TensorFlow banyak digunakan untuk keperluan *machine learning* seperti *neural networks*. Pada awalnya TensorFlow digunakan secara



tertutup oleh tim riset *Google*, yang kemudian dibuka untuk umum pada November 2015 untuk demokratisasi riset *Deep Learning*. TensorFlow menyediakan beberapa macam (Keras, Estimator, Core) *Application Programming Interface* (API) *neural networks* sesuai dengan kebutuhan penggunaanya. Kini fasilitas yang disediakan oleh TensorFlow dapat digunakan melalui bahasa pemrograman dasar seperti Python dan R (Rstudio, 2019).

### 2.13 Keras

Keras adalah *Application Programming Interface* (API) *neural networks* tingkat tinggi yang dikembangkan dengan fokus untuk keperluan riset dan komputasi eksperimen. Keperluan Keras dituangkan dalam bentuk fungsi dan paket *Deep Learning* yang berperan dalam pembuatan model. Keras dapat berjalan dengan sistem *back-end* TensorFlow, Theano, atau CNTK (Rstudio, 2019).

## BAB III METODE PENELITIAN

### 3.1 Lokasi dan Waktu

Penelitian dilaksanakan pada dua tempat yang berbeda yaitu di Stasiun BMKG Karangploso Kab. Malang dan Kediaman penulis yang berada di Kota Malang.

### 3.2 Alat dan Bahan

Alat yang digunakan dalam penelitian adalah sebuah Laptop ASUS ROG Strix GL503 Gaming PC, dengan Spesifikasi, CPU: 2.8GHz Intel Core i7-7700HQ (quad-core, 6MB cache, up to 3.8GHz); Grafik: Nvidia GeForce GTX 1050ti (4GB GDDR5 VRAM); Intel HD Graphics 630; RAM: 8GB DDR4 (dual channel; 2,400MHz); Hard Drive 1 TB.

Bahan yang digunakan dalam penelitian adalah Data Suhu Permukaan Laut Bulanan Global dari bulan Desember tahun 1981 sampai 2018 bulan Oktober dari *National Oceanic and Atmospheric Administration* (NOAA), Amerika Serikat.

### 3.3 Tahapan Penelitian

Penelitian ini dilakukan dalam beberapa tahap sebagai berikut:

1. Persiapan Perangkat Lunak (*Software*)
2. Pengambilan Data
3. Pengolahan Data
4. Pembuatan *Model Neural Network*
5. Pelatihan *Neural Network* (*Training*)
6. Pengujian *Neural Network* (*Testing*)

#### 3.3.1 Persiapan Perangkat Lunak


Sebelum memulai penelitian, Program Prediksi Nilai SPL Global yang akan dibuat menggunakan perangkat lunak *back-end* Tensorflow, TensorFlow dibangun menggunakan bahasa

pemrograman R. Diperlakukan penginstalan R-Project dan IDE R terlebih dahulu agar script program dapat diolah.

R-Project dapat diunduh melalui salah satu website resmi R yaitu, <https://www.rstudio.com/products/rstudio/download/>. Sementara

untuk Rstudio dapat diunduh melalui website resmi R lainnya yaitu <https://www.rstudio.com/products/rstudio/download/>. Setelah

diunduh lakukan langkah-langkah penginstalan sesuai dengan panduan (gambar 3.1), tunggu hingga instalasi selesai.



Gambar 3. 1 Install Rstudio IDE

Lalu buka Rstudio, lakukan instalasi packages library yang diperlukan agar program dapat dirancang. Berikut daftar library R-Project yang digunakan dibagi berdasarkan kegunaannya:

- Untuk keperluan membersihkan dan merapikan data:
  - tidyverse
  - glue
  - forcats
- Untuk keperluan mengolah data time series:





- timetk
- tidyquant
- tibbletime
- lubridate
- Untuk visualisasi data:
  - cowplot
- Untuk mempersiapkan data sebelum diproses:
  - recipes
- Untuk pengambilan sample dan uji akurasi:
  - rsample
  - yardstick
- Untuk pembuatan model:
  - keras

Untuk melakukan instalasi library R-Project gunakan perintah “install.packages(‘nama\_library\_package’)” melalui console pada Rstudio seperti berikut:

```
install.packages(‘tidyverse’)
install.packages(‘glue’)
```

Setelah semua library terpasang, program siap untuk dibuat dan dijalankan melalui Rstudio.

### 3.3.2 Pengambilan Data

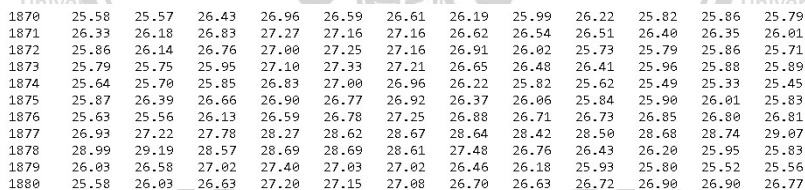
Data didapatkan melalui website resmi NOAA pada Maret 2018. *File* tersebut berisi data nilai rata-rata suhu permukaan laut (SPL) area Nino 3, 4, dan 3.4 bulanan —data masing-masing area diunduh pada situs terpisah—, dimulai dari bulan Januari tahun 1981 sampai dengan bulan Desember tahun 2018 dengan pengamatan satelit NOAA. Data rata-rata SPL pada daerah Nino 3, 4, dan 3.4 yang diambil pada situs merupakan data yang telah diolah dari alat-alat instrumen observasi mereka.

Berikut adalah website URL data yang diambil untuk penelitian ini:

- [https://www.esrl.noaa.gov/psd/gcos\\_wgsp/Timeseries/Nino34/](https://www.esrl.noaa.gov/psd/gcos_wgsp/Timeseries/Nino34/)
- [https://www.esrl.noaa.gov/psd/gcos\\_wgsp/Timeseries/Nino3/](https://www.esrl.noaa.gov/psd/gcos_wgsp/Timeseries/Nino3/)
- [https://www.esrl.noaa.gov/psd/gcos\\_wgsp/Timeseries/Nino4/](https://www.esrl.noaa.gov/psd/gcos_wgsp/Timeseries/Nino4/)

Penelitian ini menggunakan data SPL pada area Nino 3, Nino 4, dan Nino 3.4 yang didapat dari situs *website* NOAA, yang berisi data *time series* dari Januari tahun 1871 sampai dengan Desember tahun 2018 (147 tahun/1764 bulan). Penggunaan tiga data SPL dari area Nino 3, 4, dan 3.4 adalah variabel data input yang akan diberikan kepada model RNN-LSTM. Dalam penelitian ini data yang diambil untuk pelatihan model adalah sebanyak 48 tahun/576 bulan, dari Januari 1970 sampai Desember 2018. Pemilihan waktu atas data yang digunakan didasari atas model RNN-LSTM yang akan memprediksi nilai suhu permukaan laut pada tahun 1997, 2007, 2010, 2015, 2018 dan 2019.

Data yang akan diolah berupa data *time series* dengan nilai rata-rata suhu permukaan laut di tiap bulannya yang disimpan dalam bentuk matriks dua dimensi (2D) dengan ukuran 147x12, yang artinya terdapat 147 kolom dan 12 baris data seperti pada gambar 3.2.



1870	25.58	25.57	26.43	26.96	26.59	26.61	26.19	25.99	26.22	25.82	25.86	25.79
1871	26.33	26.18	26.83	27.27	27.16	27.16	26.62	26.54	26.51	26.40	26.35	26.01
1872	25.86	26.14	26.76	27.00	27.25	27.16	26.91	26.02	25.73	25.79	25.86	25.71
1873	25.79	25.75	25.95	27.10	27.33	27.21	26.65	26.48	26.41	25.96	25.88	25.89
1874	25.64	25.70	25.85	26.83	27.00	26.96	26.22	25.82	25.62	25.49	25.33	25.45
1875	25.87	26.39	26.66	26.90	26.77	26.92	26.37	26.06	25.84	25.90	26.01	25.83
1876	25.63	25.56	26.13	26.59	26.78	27.25	26.88	26.71	26.73	26.85	26.80	26.81
1877	26.93	27.22	27.78	28.27	28.62	28.67	28.64	28.42	28.50	28.68	28.74	29.07
1878	28.99	29.19	28.57	28.69	28.69	28.61	27.48	26.76	26.43	26.20	25.95	25.83
1879	26.03	26.58	27.02	27.40	27.03	27.02	26.46	26.18	25.93	25.80	25.52	25.56
1880	25.58	26.03	26.63	27.20	27.15	27.08	26.70	26.63	26.72	26.90	26.90	26.77

Gambar 3. 2 Struktur data Nino dalam bentuk matriks pada situs NOAA

Data tersebut lalu di-copy kedalam excel yang kemudian disimpan dalam format .csv dengan nama:

- "nino34\_noaa\_sst\_value\_before\_index.csv"
- "nino3\_noaa\_sst\_value\_before\_index.csv"
- "nino4\_noaa\_sst\_value\_before\_index.csv"

untuk diubah strukturnya dari gambar 3.1 menjadi seperti pada tabel 3.1 dengan *command function* pada *software R*.

Tabel 3. 1 Struktur data frame Nino 3, 4, & 3.4 diubah menjadi 2 kolom

Nino 3		Nino 4		Nino 3.4	
value	date	value	date	value	date
25.33	1871-01-01	27.72	1871-01-01	26.33	1871-01-01
25.83	1871-02-01	27.69	1871-02-01	26.18	1871-02-01
26.65	1871-03-01	27.84	1871-03-01	26.83	1871-03-01
26.91	1871-04-01	28.1	1871-04-01	27.27	1871-04-01
26.22	1871-05-01	28.11	1871-05-01	27.16	1871-05-01
25.93	1871-06-01	28.11	1871-06-01	27.16	1871-06-01
25.07	1871-07-01	27.91	1871-07-01	26.62	1871-07-01
24.66	1871-08-01	28.12	1871-08-01	26.54	1871-08-01
24.59	1871-09-01	28.23	1871-09-01	26.51	1871-09-01


Setelah data dari masing-masing area sudah dalam struktur yang sama ketiga data daerah/area yang akan diolah tersebut kemudian disatukan menjadi dalam satu file yang sama seperti pada tabel 3.2 agar data dapat diolah lebih lanjut pada tahap pengolahan data yang jika digambarkan dalam bentuk plot seperti pada gambar 3.2.

Tabel 3. 2 Struktur dataframe Nino 3, 4, & 3.4 disatukan kedalam satu file

index	sst_nino34	sst_nino3	sst_nino4
1/1/1981	26.12	24.84	28.15
2/1/1981	26.31	25.69	28.07
3/1/1981	27.24	26.87	28.47
4/1/1981	27.6	27.14	28.42
5/1/1981	27.76	26.85	28.76
6/1/1981	27.54	26.42	28.53
7/1/1981	26.79	25.24	28.35
8/1/1981	26.7	24.68	28.36
9/1/1981	26.68	24.93	28.52




Nino 3: 1970 to 2018 (Zoomed Into Show Cycle)




NOAA SST Observation Data

Nino 4: 1970 to 2018 (Zoomed Into Show Cycle)



NOAA SST Observation Data

Nino 3.4: 1970 to 2018 (Zoomed Into Show Cycle)



NOAA SST Observation Data

Gambar 3.2 Plot Data Suhu Permukaan Laut pada Daerah Nino 3, 4, & 3.4 dari tahun 1970-2018

### 3.3.3 Pengolahan Data

Model pembelajaran yang digunakan adalah *supervised learning* dimana *Neural Network* memerlukan data yang telah diberi label atau dikelompokkan. Lalu model diberikan data input sebagai *training set* untuk pelatihan modelnya serta data output sebagai *testing set* yang kemudian akan di gunakan sebagai target untuk melakukan proses pengujiannya. Kemudian data dari tahun 1970-2018 dibagi menjadi dua bagian sesuai perannya yaitu, data untuk pelatihan (*training set*) dan data untuk pengujian (*testing set*) pada model *Neural Network* seperti yang bisa dilihat pada tabel 3.3.

Tabel 3.3 Sampel Data Dibagi Training set dan Testing set yang telah di normalisasi

index	sst_nino34	sst_nino3	sst_nino4	key	index	sst_nino34	sst_nino3	sst_nino4	key
1/1/1989	-2.56442	-1.37114	-2.88	training	6/1/2018	0.739475	0.592125	0.686667	testing
2/1/1989	-1.75628	-0.26168	-2.76101	training	7/1/2018	0.415867	-0.02273	0.715151	testing
3/1/1989	-1.18941	0.135797	-2.30159	training	8/1/2018	-0.15501	-0.80854	0.72939	testing
4/1/1989	-0.43238	0.560814	-1.58075	training	9/1/2018	-0.03219	-0.68728	0.885853	testing
5/1/1989	-0.02196	0.309479	-0.79375	training	10/1/2018	0.496945	-0.19782	1.282799	testing
6/1/1989	-0.04241	0.112057	-0.92439	training	11/1/2018	0.577905	0.064535	1.169579	testing

Setelah dilakukan pembagian data training set dan testing set pada sampel, kemudian dilakukan normalisasi pada data dari rentang -3 sampai 3 agar model dapat mengolah data lebih mudah. pada dasarnya dalam pelatihan model, data dibagi menjadi tiga kelompok, Data pelatihan, Validasi dan 1 baris data untuk Pengujian. Namun dalam pembagian data yang digunakan pada penelitian ini, peneliti menggunakan *default setting* pada proses pelatihan model dimana data training set secara otomatis dibagi lagi menjadi dua bagian dengan  $\frac{3}{4}$  Data Pelatihan dan  $\frac{1}{4}$  Validasi.

### 3.3.4 Pembuatan Model Neural Network

Model *Neural Network* yang digunakan adalah *single LSTM* dengan tiga *layer*. Dua hidden layer masing-masing berisikan 50 artificial neuron LSTM, satu output layer yang berisikan 1 neuron biasa. Fungsi aktivasi yang digunakan pada setiap neuron adalah *tanh*. Data input diolah terlebih dahulu pada Hidden Layer LSTM lapisan pertama yang terdiri dari 50 neuron LSTM kemudian dari Hidden Layer pertama diolah kembali ke Hidden Layer kedua. Setelah diolah di kedua Hidden Layer LSTM, maka hasil olahan data akan didistribusikan menuju Dense Layer (Fully Connected Layer). Dense Layer akan menghasilkan data output.

### 3.3.5 Pelatihan Neural Network

Data input yang diberikan kepada model berisikan tiga variabel yaitu data rata-rata SPL bulanan dengan sampel berurutan pada area Nino 3, 4, dan 3.4. Kemudian data input akan diproses ke dalam model RNN-LSTM. Model tersebut akan menghasilkan output nilai berupa interpolasi/prediksi rata-rata SPL di area Nino 3.4 untuk beberapa bulan kedepan—disesuaikan dengan perintah pada program. Data output tersebut kemudian dibandingkan dengan Data Validasi. Jika data tidak sesuai saat perbandingan dengan Data Validasi maka dilakukan perubahan bobot pada masing-masing *artificial neuron* yang ada agar output yang dihasilkan dapat sesuai dengan target, selagi pada fase validasi model akan menghasilkan nilai *error/kesalahan*, dimana nilai kesalahan ini dihitung menggunakan *Mean Square Error*. Hasil kesalahan tersebut akan digunakan untuk memperbarui nilai bobot yang ada. Pada model ini digunakan algoritma optimasi untuk mengubah dan memperbaiki bobot yang ada dengan “Adam Optimizer” dan “Adagrad Optimizer” sebagai algoritma optimasinya. *Adagrad optimizer* dipilih berdasarkan penelitian yang dilakukan oleh Qin Zhang dalam memprediksi nilai SPL pada laut Bohai, Adagrad adalah algoritma optimasi penurunan gradien stokastik sama seperti algoritma optimasi Adam. Adam *optimizer* merupakan algoritma yang dikembangkan dengan mengkombinasikan *optimizer* Adagrad dan Rmsprop, dalam pembuatan model *deep learning* fungsi optimasi tersebut (Adam) sangat umum digunakan oleh para praktisi *machine learning* atau ilmuwan data, dan seringkali dikatakan mengkombinasikan dari dua fungsi optimasi terbaik dalam mengolah data besar.

Data yang digunakan untuk keperluan proses *training* dibagi menjadi dua macam yaitu Data Pengujian dan Validasi. Tujuannya adalah untuk memastikan bahwa model dapat melakukan proses





pembelajaran serta dapat memahami data yang telah diberikan dalam bentuk performa prediksi yang maksimal.

### 3.3.6 Pengujian Neural Network

Pengujian dilakukan sebanyak empat kali percobaan dengan fungsi optimasi Adam dan Adagrad. Pada percobaan yang pertama hasil keakuratan model RNN-LSTM dengan variasi jumlah input seperti tertera pada tabel 3.4 akan dibandingkan untuk memprediksi tahun 2018. Terdapat 16 variasi data input dari 16 tahun sampai 31 tahun. Pemilihan variasi input tersebut didasari atas penelitian yang dilakukan oleh Qin Zhang, dimana ia menggunakan 31 tahun input data SPL laut bohai untuk memperoleh hasil terbaik. Sementara untuk pemilihan 16 tahun sebagai awal pengujian agar model dapat menangkap dan mempelajari fenomena ENSO ringan hingga ekstrim selama satu dekade terakhir dari data yang ada.

Tabel 3. 4 Pengujian model dengan data tahun input yang berbeda-beda

No	Panjang Tahun	Data Tahun Input	Tahun Prediksi
1	16 tahun	2001-2017	2018
2	17 tahun	2000-2017	2018
3	18 tahun	1999-2017	2018
4	19 tahun	1998-2017	2018
5	20 tahun	1997-2017	2018
6	21 tahun	1996-2017	2018
7	22 tahun	1995-2017	2018
8	23 tahun	1994-2017	2018
9	24 tahun	1993-2017	2018
10	25 tahun	1992-2017	2018
11	26 tahun	1991-2017	2018

12	27 tahun	1990-2017	2018
13	28 tahun	1989-2017	2018
14	29 tahun	1988-2017	2018
15	30 tahun	1987-2017	2018
16	31 tahun	1986-2017	2018

Pada pengujian kedua, tiga model dengan performa terbaik pada pengujian pertama akan diuji kembali untuk memprediksi nilai rata-rata SPL selama 6 bulan, 9 bulan, dan 12 bulan pada tahun 2018. terdapat tiga variasi output dengan durasi panjang prediksi selama 1 tahun (Januari – Desember 2018), 9 bulan (April – Desember 2018), 6 bulan (Juli – Desember 2018).

Tabel 3. 5 Pengujian kedua dengan panjang bulan yang berbeda-beda

Data Tahun Input	Prediksi	Panjang Prediksi
Jan 2000 - Des 2017	Jan - Des 2018	12 Bulan
Apr 1999 - Mar 2018	Apr - Des 2018	9 Bulan
Jul 1999 - Jun 2018	Jul -Des 2018	6 Bulan

Pada pengujian ketiga, model dengan performa terbaik pada pengujian pertama akan diuji untuk memprediksi nilai anomali rata-rata SPL di tahun yang berbeda-beda yaitu 2014, 2017 dan 2018. Model akan memprediksi nilai anomali SPL selama 12 bulan pada tahun-tahun tersebut dimulai dari bulan Januari hingga Desember. Tahun pada 2015 sampai dengan 2016 dihindari pada pengujian ini karena akan dibahas lebih khusus pada pengujian selanjutnya karena masuk pada keadaan tersebut terjadi anomali SPL dalam kondisi El Nino ekstrim.


Tabel 3. 6 Pengujian ketiga dengan tahun yang berbeda-beda

Data Tahun Input	Prediksi	Panjang Prediksi
Jan 1990 - Des 2017	Jan - Des 2018	12 Bulan
Jan 1989 - Des 2016	Jan - Des 2017	12 Bulan
Jan 1986 - Des 2013	Jan - Des 2014	12 Bulan

Pada pengujian keempat, model dengan performa paling baik pada pengujian pertama akan diuji untuk memprediksi nilai rata-rata SPL di kondisi ekstrim (gambar 3.3) yaitu La Nina pada tahun 2010–2011, dan El Nino pada tahun 2015–2016.

Tabel 3. 7 Pengujian keempat ketika daera Nino berada pada kondisi Ekstrim

No	Tahun Prediksi	Kondisi
1	2015-2016	El Nino Sangat Kuat
2	2010-2011	La Nina Kuat



Gambar 3.3 Oceanic Niño Index (ONI) dengan indikasi fase anomali suhu permukaan laut; waktu yang dilingkari merupakan waktu yang akan diprediksi oleh model

Seluruh data hasil prediksi menggunakan model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad tersebut akan dibandingkan dengan data sesungguhnya kemudian dihitung nilai kesalahan totalnya menggunakan *Root Mean Square Error* untuk



menggambarkan seberapa akurat model tersebut dalam memprediksi nilai rata-rata SPL bulanan.



## BAB IV HASIL DAN PEMBAHASAN


### 4.1 Prediksi Model dengan Variasi Panjang Tahun Input

Dilakukan pengujian pada model RNN-LSTM dengan variasi input dari 16 sampai 31 tahun untuk memprediksi nilai SPL pada tahun 2018 menggunakan fungsi optimasi Adam dan Adagrad. Pada pengujian ini diperoleh tiga model dengan performa terbaik dari model dengan fungsi optimasinya. Seperti pada tabel 4.1 model yang menggunakan fungsi optimasi Adam memiliki performa terbaik pada input sebanyak 18, 25, dan 26 tahun. Sementara model yang menggunakan fungsi optimasi Adagrad memiliki performa terbaik pada input sebanyak 27, 28, dan 29 tahun. Jika kedua model dengan fungsi optimasi dibandingkan secara menyeluruh Model dengan fungsi optimasi Adagrad memiliki nilai RMSE yang lebih rendah dibandingkan model dengan fungsi optimasi Adam, meskipun nilai RMSE terendah diperoleh dari model dengan fungsi optimasi Adam dengan nilai RMSE 0.48 °C.

Tabel 4. 1 Prediksi dengan input yang berbeda

No	Panjang Tahun	Data Tahun Input	Tahun Prediksi	Adam Optimizer: RMSE [oC]	Adagrad Optimizer: RMSE [oC]
1	16 tahun	2001-2017	2018	0.89	0.78
2	17 tahun	2000-2017	2018	0.95	0.81
3	18 tahun	1999-2017	2018	<b>0.79</b>	0.79
4	19 tahun	1998-2017	2018	0.89	0.86
5	20 tahun	1997-2017	2018	1.25	0.85
6	21 tahun	1996-2017	2018	1.23	1.03
7	22 tahun	1995-2017	2018	1.07	0.76
8	23 tahun	1994-2017	2018	1.19	0.75
9	24 tahun	1993-2017	2018	0.86	0.88
10	25 tahun	1992-2017	2018	<b>0.48</b>	0.7
11	26 tahun	1991-2017	2018	<b>0.81</b>	0.69
12	27 tahun	1990-2017	2018	0.99	<b>0.63</b>
13	28 tahun	1989-2017	2018	<b>1</b>	<b>0.68</b>
14	29 tahun	1988-2017	2018	0.98	<b>0.64</b>
15	30 tahun	1987-2017	2018	1.11	0.79
16	31 tahun	1986-2017	2018	1.36	0.85


Berdasarkan pengujian yang dilakukan secara menyeluruh diperoleh hasil bahwa semakin banyak data area SPL Nino 3, 4, dan 3.4 dari 16 sampai 31 tahun yang digunakan sebagai input memiliki *trend line* yang berbeda jika ditinjau dari fungsi optimasinya seperti pada gambar 4.1. Pada model dengan fungsi optimasi Adam jika dilihat dari grafik trennya, model tersebut memiliki kecenderungan untuk meningkatnya nilai RMSE ketika semakin banyak data input yang diberikan. Sementara model dengan fungsi optimasi Adagrad justru sebaliknya, semakin banyak data input yang diberikan semakin menurun nilai RMSEnya.



Gambar 4. 1 Grafik tren fungsi optimasi Adam dan Adagrad prediksi dengan variasi tahun input



Adapun permasalahan output nilai prediksi yang dikeluarkan model dengan fungsi optimasi Adam dan Adagrad pada tahun 2018. Salah satunya yaitu model beberapa kali mengalami permasalahan akan waktu prediksinya yang dirasa lebih cepat satu bulan jika dibandingkan dengan waktu aslinya. Jika nilai prediksi dimajukan satu bulan maka diperoleh nilai RMSE yang lebih rendah dibanding sebelumnya, tetapi nilai prediksi pada awal bulan menjadi hilang seperti pada gambar 4.3. Kendala seperti ini nampaknya bukan sebuah kesalahan yang didapatkan pada tiap prediksinya, dikarenakan pada saat model memprediksi nilai anomali SPL pada tahun 2014 dan 2016 tidak terjadi kendala seperti pada tahun 2018 dimana prediksi dirasa lebih cepat satu bulan.



Gambar 4. 2 Grafik prediksi anomali SPL tahun 2018 dengan input sebanyak 27 tahun menggunakan fungsi optimasi Adagrad sebelum dimajukan 1 bulan

Input(27 Tahun) & Output(Tahun 2018),  
RMSE: 0.36



Gambar 4. 3 Grafik prediksi anomali SPL tahun 2018 dengan input sebanyak 27 tahun menggunakan fungsi optimasi Adagrad setelah dimajukan 1 bulan

## 4.2 Prediksi Model untuk Variasi Panjang Waktu

Model RNN-LSTM dengan performa terbaik dari pengujian sebelumnya diuji kembali untuk melakukan prediksi selama 6, 9 dan 12 bulan di tahun 2018. Model akan memprediksi nilai anomali SPL dari bulan Desember 2018 kemudian bergerak mundur. Jika model akan memprediksi selama 6 bulan dengan data input sebanyak 18 tahun maka model akan memprediksi bulan Desember 2018 dan 5 bulan yang ada dibelakangnya, dengan begitu data input yang akan diberikan dimulai dari Juli 1999 sampai dengan Juni 2018 agar didapatkan total waktu pelatihan sebanyak 18 tahun. Sementara jika model akan memprediksi selama 9 bulan dengan data input sebanyak 18 tahun maka model akan memprediksi bulan Desember 2018 dan 8 bulan dibelakangnya, sehingga data input yang akan diberikan dimulai dari April 1999 sampai dengan Maret 2018 agar didapatkan total waktu pelatihan sebanyak 18 tahun. Begitu juga hal yang sama dilakukan untuk prediksi selama 12 bulan ataupun dengan data input untuk 25 dan 26 tahun dalam pemberian datanya.

Tabel 4. 2 Model dengan performa terbaik prediksi output untuk 6, 9 dan 12 bulan menggunakan fungsi optimasi Adam

No	Panjang Tahun	Data Tahun Input	Prediksi	Panjang Prediksi	Adam Optimizer: RMSE [oC]
1	18	Jan 2000 - Des 2017	Jan - Des 2018	12 Bulan	0.79
2	18	Apr 1999 - Mar 2018	Apr - Des 2018	9 Bulan	0.36
3	18	Jul 1999 - Jun 2018	Jul - Des 2018	6 Bulan	0.55
1	25	Jan 1992 - Des 2017	Jan - Des 2018	12 Bulan	0.48
2	25	Apr 1991 - Mar 2018	Apr - Des 2018	9 Bulan	0.29
3	25	Jul 1991 - Jun 2018	Jul - Des 2018	6 Bulan	0.49
1	26	Jan 1991 - Des 2017	Jan - Des 2018	12 Bulan	0.81
2	26	Apr 1990 - Mar 2018	Apr - Des 2018	9 Bulan	0.4
3	26	Jul 1990 - Jun 2018	Jul - Des 2018	6 Bulan	0.83


Tabel 4. 3 Model dengan performa terbaik prediksi output untuk 6, 9 dan 12 bulan menggunakan fungsi optimasi Adagrad

No	Panjang Tahun	Data Tahun Input	Prediksi	Panjang Prediksi	Adagrad Optimizer: RMSE [oC]
1	27	Jan 1990 - Des 2017	Jan - Des 2018	12 Bulan	0.63
2	27	Apr 1989 - Mar 2018	Apr - Des 2018	9 Bulan	0.3
3	27	Jul 1989 - Jun 2018	Jul - Des 2018	6 Bulan	0.32
1	28	Jan 1989 - Des 2017	Jan - Des 2018	12 Bulan	0.68
2	28	Apr 1988 - Mar 2018	Apr - Des 2018	9 Bulan	0.47
3	28	Jul 1988 - Jun 2018	Jul - Des 2018	6 Bulan	0.24
1	29	Jan 1988 - Des 2017	Jan - Des 2018	12 Bulan	0.64
2	29	Apr 1987 - Mar 2018	Apr - Des 2018	9 Bulan	0.4
3	29	Jul 1987 - Jun 2018	Jul - Des 2018	6 Bulan	0.22

Model RNN-LSTM dengan fungsi optimasi Adam dan Adagrad memiliki hasil yang berbeda ketika memprediksi nilai Anomali SPL pada waktu 6, 9 dan 12 bulan. Dilihat secara menyeluruh pada tabel 4.3 model dengan fungsi optimasi Adagrad menunjukkan nilai RMSE yang lebih kecil dibandingkan Model dengan fungsi optimasi Adam pada tabel 4.2. Selain itu jika dilihat pada gambar 4.4 model dengan fungsi optimasi Adam memiliki ketidak stabilan dalam memprediksi anomali SPL dilihat dari nilai RMSEnya yang dirasa tidak stabil. Sementara model dengan fungsi optimasi Adagrad memberikan nilai prediksi yang stabil di tiap prediksinya, semakin pendek waktu yang



diprediksi, model tersebut mampu memberikan prediksi dengan nilai RMSE yang lebih rendah dibanding jika model harus memprediksi waktu yang lebih panjang.



Gambar 4. 4 Plot RMSE pada tiga model terbaik untuk panjang bulan yang berbeda

### 4.3 Prediksi Model untuk Variasi Tahun

Model RNN-LSTM dengan performa terbaik dari pengujian sebelumnya diuji kembali untuk memprediksi waktu yang berbeda dengan panjang waktu prediksi yang sama (12 bulan/1 tahun) pada tahun 2014 dan 2017. Pada pemilihan waktu prediksi untuk tahun 2015 dan 2016 dihindari dalam pembahasan ini karena pada saat dua tahun tersebut sedang terjadi kondisi Nino ekstrim yang pada sub bab selanjutnya akan dibahas. Data tahun *input* yang diberikan sesuai dengan panjang waktu prediksi yang diperintahkan seperti yang tertera pada tabel 4.5 dan 4.6. Semisal, ketika memprediksi tahun 2017 menggunakan model dengan data input sebanyak 18 tahun maka akan digunakan data dari Januari 1998 sampai dengan Desember 2016 dan jika memprediksi tahun 2014 maka digunakan data dari Januari 1995

sampai dengan Desember 2013 begitu juga untuk model dengan data input lainnya.

Tabel 4. 4 Model dengan performa terbaik prediksi output dengan tahun berbeda menggunakan fungsi optimasi Adam


No	Panjang Tahun	Data Tahun Input	Prediksi	Panjang Prediksi	Adam Optimizer: RMSE [oC]
1	18	Jan 2000 - Des 2017	Jan - Des 2018	12 Bulan	0.79
2	18	Jan 1998 - Des 2016	Jan - Des 2017	12 Bulan	1.13
3	18	Jan 1995 - Des 2013	Jan - Des 2014	12 Bulan	0.56
1	25	Jan 1992 - Des 2017	Jan - Des 2018	12 Bulan	0.48
2	25	Jan 1991 - Des 2016	Jan - Des 2017	12 Bulan	0.91
3	25	Jan 1988 - Des 2013	Jan - Des 2014	12 Bulan	1.15
1	26	Jan 1991 - Des 2017	Jan - Des 2018	12 Bulan	0.81
2	26	Jan 1990 - Des 2016	Jan - Des 2017	12 Bulan	1.27
3	26	Jan 1987 - Des 2013	Jan - Des 2014	12 Bulan	1.12

Tabel 4. 5 Model dengan performa terbaik prediksi output dengan tahun berbeda menggunakan fungsi optimasi Adagrad

No	Panjang Tahun	Data Tahun Input	Prediksi	Panjang Prediksi	Adagrad Optimizer: RMSE [oC]
1	27	Jan 1990 - Des 2017	Jan - Des 2018	12 Bulan	0.63
2	27	Jan 1989 - Des 2016	Jan - Des 2017	12 Bulan	0.7
3	27	Jan 1986 - Des 2013	Jan - Des 2014	12 Bulan	0.88
1	28	Jan 1989 - Des 2017	Jan - Des 2018	12 Bulan	0.68
2	28	Jan 1988 - Des 2016	Jan - Des 2017	12 Bulan	0.91
3	28	Jan 1985 - Des 2013	Jan - Des 2014	12 Bulan	0.83
1	29	Jan 1988 - Des 2017	Jan - Des 2018	12 Bulan	0.64
2	29	Jan 1987 - Des 2016	Jan - Des 2017	12 Bulan	0.91
3	29	Jan 1984 - Des 2013	Jan - Des 2014	12 Bulan	0.7

Tabel 4.5 dan 4.6 menunjukan nilai *Root Mean Square Error* pada tahun 2014, 2017 dan 2018. Pada model dengan fungsi optimasi Adam dan Adagrad ketika memprediksi nilai anomali SPL pada tahun 2017 dan 2014 model mengalami kenaikan nilai RMSE jika dibandingkan dengan prediksi pada tahun 2018 seperti pada gambar 4.4. Hal ini mungkin di karenakan pada tahun tersebut kondisi Nino berada pada keadaan moderat sementara pada tahun 2018 kondisi Nino sedang berada pada kondisi lemah. Jika dibandingkan performa antara

dua model tersebut, dapat dilihat bahwa model yang menggunakan fungsi optimasi Adagrad memiliki nilai RMSE yang lebih stabil dalam melakukan prediksi dibandingkan dengan model dengan fungsi optimasi Adam, meskipun nilai RMSE terendah diperoleh model dengan fungsi optimasi Adam pada tahun 2014 dan 2018.



Gambar 4. 5 Plot RMSE pada tiga model terbaik untuk tahun yang berbeda-beda

#### 4.4 Prediksi Model Saat Kondisi Ekstrim

Model RNN-LSTM dengan performa terbaik pada pengujian sebelumnya diuji kembali untuk memprediksi kondisi-kondisi ekstrim El Nino dan La Nina. Sama seperti pada pengujian sebelumnya, namun kali ini model akan diuji performanya untuk memprediksi kondisi El Nino ekstrim tahun 2015 sampai 2016 dan La Nina ekstrim tahun 2010 sampai 2011. Kondisi ekstrim atau fluktuasi SPL tersebut terjadi selama dua tahun sehingga dilakukan prediksi dua tahun secara langsung untuk melihat apakah model dapat menangkap atau memperkirakan adanya pola ekstrim tersebut. Tertera pada tabel 4.7



dan 4.8 akan hasil nilai RMSE dari model dengan performa terbaik dari pengujian sebelumnya.

Tabel 4. 6 Model dengan performa terbaik prediksi output pada kondisi ekstrim menggunakan fungsi optimasi Adam


No	Panjang Tahun	Data Tahun Input	Tahun Prediksi	Adam Optimizer: RMSE [oC]	Kondisi
1	18 tahun	1996-2014	2015-2016	1.24	El Nino Sangat Kuat
2	25 tahun	1989-2014	2015-2016	1.22	El Nino Sangat Kuat
3	26 tahun	1988-2014	2015-2016	1.25	El Nino Sangat Kuat
1	18 tahun	1991-2009	2010-2011	1.73	La Nina Kuat
2	25 tahun	1984-2009	2010-2011	1.51	La Nina Kuat
3	26 tahun	1983-2009	2010-2011	1.59	La Nina Kuat

Tabel 4. 7 Model dengan performa terbaik prediksi output pada kondisi ekstrim menggunakan fungsi optimasi Adagrad

No	Panjang Tahun	Data Tahun Input	Tahun Prediksi	Adagrad Optimizer: RMSE [oC]	Kondisi
1	27 tahun	1987-2014	2015-2016	1.44	El Nino Sangat Kuat
2	28 tahun	1986-2014	2015-2016	1.49	El Nino Sangat Kuat
3	29 tahun	1985-2014	2015-2016	1.36	El Nino Sangat Kuat
1	27 tahun	1982-2009	2010-2011	1.17	La Nina Kuat
2	28 tahun	1981-2009	2010-2011	1.12	La Nina Kuat
3	29 tahun	1980-2009	2010-2011	1.22	La Nina Kuat


Kedua model dengan fungsi optimasi Adam ataupun Adagrad memiliki nilai RMSE yang cukup tinggi untuk memprediksi nilai anomali pada kondisi ekstrim El Nino dan La Nina. Jika dilihat dari segi nilai RMSEnya bisa dikatakan model kurang baik dalam memprediksikan nilai anomali SPL pada kondisi ekstrim tersebut. Meskipun demikian masing-masing model dengan fungsi optimasinya memberikan hasil yang berbeda ketika melakukan prediksi atau penggambaran pola non linear dari fluktuasi SPL pada kondisi El Nino (tahun 2015-2016) dan La Nina Ekstrim (tahun 2010-2011). Pada model yang menggunakan fungsi optimasi Adam dapat menangkap adanya fluktuasi nilai SPL pada empat bulan pertama saat kondisi El Nino ekstrim seperti yang ditunjukkan pada gambar 4.5, tetapi gagal dalam menemukan pola non linear untuk kondisi La Nina ekstrim

seperti pada gambar 4.6. Sementara model dengan fungsi optimasi Adagrad sedikit lebih baik dalam memprediksi pola non linear anomali SPL saat kondisi La Nina ekstrim dibandingkan model dengan fungsi optimasi Adam seperti pada gambar 4.7, tetapi gagal dalam memprediksi nilai anomali SPL saat kondisi El Nino Ekstrim seperti yang ditunjukkan pada gambar 4.8.




Gambar 4. 6 Grafik prediksi anomali SPL pada kondisi El Nino ekstrim tahun 2015-2016 menggunakan model dengan fungsi optimasi Adam

Input(25 Tahun) & Output(2010 - 2011),  
RMSE: 1.51



Gambar 4. 7 Grafik prediksi anomali SPL pada kondisi La Nina ekstrim tahun 2010-2011 menggunakan model dengan fungsi optimasi Adam


Input(29 Tahun) & Output(2015 - 2016),  
RMSE: 1.36



Gambar 4. 8 Grafik prediksi anomali SPL pada kondisi El Nino ekstrim tahun 2015-2016 menggunakan model dengan fungsi optimasi Adagrad




Input(28 Tahun) & Output(2010 - 2011),  
RMSE: 1.12



Gambar 4. 9 Grafik prediksi anomali SPL pada kondisi La Nina ekstrim tahun 2010-2011 menggunakan model dengan fungsi optimasi Adagrad

#### 4.5 Prediksi Model Pada Tahun 2019

Setelah dilakukan pengujian pada Model RNN-LSTM, model kemudian digunakan untuk memprediksi nilai anomali suhu permukaan laut pada tahun 2019. Seperti pada pengujian sebelumnya tiga model dengan performa paling baik dari fungsi optimasi Adam dan Adagrad yaitu model dengan fungsi optimasi Adam menggunakan *input* 18, 25, dan 26 tahun serta model dengan fungsi optimasi Adagrad menggunakan *input* 27, 28, dan 29 tahun akan digunakan untuk memprediksi nilai anomali SPL untuk tahun 2019. Kemudian plot/grafik prediksi dari model dengan fungsi optimasi Adam akan digambarkan dalam satu plot tabel yang sama, hal yang serupa pun juga dilakukan untuk model dengan fungsi optimasi Adagrad.



Gambar 4. 10 Plot/grafik prediksi SPL pada tahun 2019 dengan tiga model terbaik dari fungsi optimasi Adam dan Adagrad

Pada gambar 4.10 model dengan fungsi optimasi Adam dan Adagrad telah memprediksi nilai anomali suhu permukaan laut pada tahun 2019. Kedua model dengan fungsi optimasi berbeda tersebut memiliki pola yang hampir sama, seperti pada bulan April sampai dengan Juni dimana kedua model tersebut menangkap akan adanya kenaikan nilai anomali SPL, lalu mulai menurun di bulan Juli sampai dengan Oktober, kemudian nilai anomali SPL naik kembali dari Oktober hingga Desember. Meski demikian model dengan fungsi optimasi Adam dan Adagrad memiliki besaran nilai yang cukup berbeda. Seperti pada model dengan input 18 tahun yang menggunakan fungsi optimasi Adam, ia memprediksi bahwa pada tahun 2019 akan terjadi La Nina dengan kondisi moderat ( $\pm 1^{\circ}\text{C}$ ) di bulan Februari. Sementara pada prediksi model lainnya tidak mendapatkan hal demikian, terutama model yang menggunakan fungsi optimasi Adagrad. Dari kedua model dengan fungsi optimasi

Adam dan Adagrad bahwa nilai anomali SPL pada tahun 2019 akan berada pada kondisi yang lemah ( $\leq \pm 1^\circ\text{C}$ ).

Tabel 4. 8 Perbandingan model dengan nilai Anomali rata-rata SPL yang telah terjadi pada bulan Januari dan Februari 2019

Menggunakan Fungsi Optimasi Adam					
No	Prediksi	Prediksi Model dengan Input: 18 Tahun	Prediksi Model dengan Input: 25 Tahun	Prediksi Model dengan Input: 26 Tahun	Nilai Anomali SPL yang Terjadi
1	Januari 2019	-0.87	<b>-0.85</b>	-0.92	0.51
2	Februari 2019	-0.41	<b>-0.16</b>	-1.37	0.68
Menggunakan Fungsi Optimasi Adagrad					
No	Prediksi	Prediksi Model dengan Input: 27 Tahun	Prediksi Model dengan Input: 28 Tahun	Prediksi Model dengan Input: 29 Tahun	Nilai Anomali SPL yang Terjadi
1	Januari 2019	<b>0.38</b>	-0.16	0	0.51
2	Februari 2019	<b>0.53</b>	-0.32	-0.07	0.68

Pada tabel 4.8 prediksi model pada tahun 2019 dibanding kan dengan data dua bulan pertama (Januari dan Februari) yang telah dikeluarkan NOAA. Berdasarkan hasil perbandingan model dengan fungsi optimasi Adam, model dengan input 18, 25, dan 26 tahun dapat dikatakan relatif kurang baik dalam menangkap pola dua bulan pertama pada bulan Januari dan Februari 2019. Namun model dengan input 25 tahun memiliki nilai anomali SPL yang cukup mendekati dengan nilai anomali SPL yang telah terjadi. Sementara pada model dengan fungsi optimasi Adagrad memiliki nilai prediksi yang sedikit lebih baik dibandingkan model dengan model dengan fungsi optimasi Adam jika ditinjau dari nilai anomali SPL yang dikeluarkan. Model dengan input tahun 28 dan 29 belum bisa menangkap kenaikan suhu yang terjadi pada bulan Januari ke Februari, akan tetapi pola kenaikan tersebut berhasil ditangkap oleh model dengan input 27 tahun.



## BAB V PENUTUP

### 5.1 Kesimpulan

Telah dilakukan penelitian untuk mengetahui kemampuan model RNN-LSTM yang dibuat dengan arsitektur 2 Hidden Layer yang terdiri dari 50 neuron LSTM pada masing-masing Hidden Layer-nya yang kemudian dapat disimpulkan ke dalam poin-poin berikut:

1. Performa prediksi anomali SPL Nino 3.4 untuk model dengan fungsi optimasi Adagrad yang didapatkan semakin baik yang disebabkan oleh data input model semakin banyak dengan ditandai nilai RMSE yang semakin mengecil. Sementara model dengan fungsi optimasi Adam memiliki kecenderungan sebaliknya, didapatkan performa prediksi semakin berkurang disebabkan banyaknya data input kedalam model dengan ditandai nilai RMSE yang semakin membesar.
2. Performa prediksi anomali SPL Nino 3.4 untuk model dengan fungsi optimasi Adagrad yang didapatkan semakin baik ketika lama waktu yang diprediksi semakin pendek secara linear. Sementara model dengan fungsi optimasi Adam dirasa tidak konsisten dalam prediksi yang dibuatnya, karena hasilnya yang fluktuatif ketika memprediksi lama waktu yang semakin pendek.
3. Performa prediksi anomali SPL Nino 3.4 untuk model dengan fungsi optimasi Adam dan Adagrad pada tahun 2018 dinilai cukup baik dalam menangkap pola non linear, tetapi mengalami penurunan performa ketika memprediksi pada tahun 2014 dan 2017. Hal tersebut dispekulasikan bahwa model lebih baik dalam memprediksi anomali SPL pada kondisi lemah ditahun 2018, tetapi kurang baik ketika



memprediksi anomali SPL pada kondisi moderat ditahun 2014 dan 2017.

4. Model dengan fungsi optimasi Adam dan Adagrad dinilai kurang baik dalam memprediksi nilai anomali SPL ataupun pola non linear pada kondisi El Nino ekstrim di tahun 2015-2016 dan La Nina ekstrim di tahun 2010-2011, jika dibandingkan dengan hasil prediksi di tahun 2014, 2017, dan 2018.

## 5.2 Saran

Pada penelitian selanjutnya, dapat dilakukan dengan beberapa saran sebagai berikut:

1. Menambahkan data *input* tahun yang lebih panjang.
2. Menambahkan data *input* faktor-faktor fisis yang mempengaruhi suhu permukaan laut (seperti Kelembaban Udara, Bintik Matahari, dan Temperatur Udara).

## Daftar Pustaka

- Adebiyi, A. & A., 2014. Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction. *Journal of Applied Mathematics*, pp. 1-7.
- Allair, F. C. & J., 2018. *Deep Learning with R*. USA: New York: Manning Publications.
- American Meteorological Society, 2012. *Weather Satellites*. New York: American Meteorological Society.
- Deser, C., 2009. Sea Surface Temperature Variability: Patterns and Mechanisms. *The Annual Review of Marine Science*, pp. 115-137.
- Errick, M. G., 2014. Introduction to Supervised Learning. *University of Massachusetts Journal*, pp. 1-2.
- Gerven, M. V., 2017. Artificial Neural Networks as Models of Neural Information Processing. *Computational Foundations of Natural Intelligence*.
- Greely, T., 1998. *Project Oceanography*. USA: Florida: Department of Marine Science, University of South Florida.
- Herculano-Houzel, S., 2016. *The Human Advantage: A New Understanding of How our Brains Became Remarkable*. USA: Massachussets: MIT Press.
- Kingma, D. P., 2015. ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION. *arXiv*.



Kok, J. N., 2009. *Artificial Intelligence. ARTIFICIAL INTELLIGENCE: DEFINITION, TRENDS, TECHNIQUES, AND CASES*, p. 3.

Krenker, A., 2011. *Artificial Neural Networks - Methodological Advances and Biomedical Applications*. Croatia: InTech.

LeCun, Y., 2015. Deep Learning. *The multidisciplinary nature of machine intelligence*, pp. 436-444.

Morgan, P., 2018. *Machine Learning is Changing the Rules*. California: O'Reilly Media, Inc..

Nilsson, N. J., 1998. INTRODUCTION TO MACHINE LEARNING. In: USA: California: Stanford University, pp. 3-4.

Qin Zhang, e. a., 2017. Prediction of Sea Surface Temperature using Long Short-Term Memory. *ArXiv*.

Rstudio, 2019. *R interface to Keras*. [Online] Available at: <https://tensorflow.rstudio.com/keras/>

Rstudio, 2019. *R interface to TensorFlow*. [Online] Available at: [www.tensorflow.rstudio.com](http://www.tensorflow.rstudio.com)

S. Hochreiter, j. S., 1997. Long short-term memory. *Neural computation*, pp. 1735-1780.


Stewart, R. H., 2008. *Introduction To Physical Oceanography*. Texas: Texas A & M University, Department of Oceanography.

The R Foundation, 2019. *What is R?*. [Online] Available at: <https://www.r-project.org/about.html>

## LAMPIRAN A DATA HASIL PENELITIAN


### A.1 Prediksi dengan jumlah input yang berbeda

Input(31 Tahun) & Output(Tahun 2018),  
RMSE: 0.85




Gambar A.1. 1Prediksi 2018 dengan 31 tahun (Adagrad)

Input(30 Tahun) & Output(Tahun 2018),  
RMSE: 0.79




Gambar A.1. 2 Prediksi 2018 dengan 30 tahun (Adagrad)

Input(29 Tahun) & Output(Tahun 2018),  
RMSE: 0.64



Gambar A.1. 3 Prediksi 2018 dengan 29 tahun (Adagrad)


Input(28 Tahun) & Output(Tahun 2018),  
RMSE: 0.68



Gambar A.1. 4 Prediksi 2018 dengan 28 tahun (Adagrad)




Input(27 Tahun) & Output(Tahun 2018),  
RMSE: 0.63




Gambar A.1. 5 Prediksi 2018 dengan 27 tahun (Adagrad)

Input(26 Tahun) & Output(Tahun 2018),  
RMSE: 0.69




Gambar A.1. 6 Prediksi 2018 dengan 26 tahun (Adagrad)

Input(25 Tahun) & Output(Tahun 2018),  
RMSE: 0.7




Gambar A.1. 7 Prediksi 2018 dengan 25 tahun (Adagrad)

Input(24 Tahun) & Output(Tahun 2018),  
RMSE: 0.88




Gambar A.1. 8 Prediksi 2018 dengan 24 tahun (Adagrad)

Input(23 Tahun) & Output(Tahun 2018),  
RMSE: 0.75



Gambar A.1. 9 Prediksi 2018 dengan 23 tahun (Adagrad)


Input(22 Tahun) & Output(Tahun 2018),  
RMSE: 0.76



Gambar A.1. 10 Prediksi 2018 dengan 22 tahun (Adagrad)




Input(21 Tahun) & Output(Tahun 18),  
RMSE: 1.03




Gambar A.1. 11 Prediksi 2018 dengan 21 tahun (Adagrad)

Input(20 Tahun) & Output(Tahun 18),  
RMSE: 0.85




Gambar A.1. 12 Prediksi 2018 dengan 20 tahun (Adagrad)

Input(19 Tahun) & Output(Tahun 2018),  
RMSE: 0.86




Gambar A.1. 13 Prediksi 2018 dengan 19 tahun (Adagrad)

Input(18 Tahun) & Output(Tahun 2018),  
RMSE: 0.79




Gambar A.1. 14 Prediksi 2018 dengan 18 tahun (Adagrad)

Input(17 Tahun) & Output(Tahun 2018),  
RMSE: 0.81



Gambar A.1. 15 Prediksi 2018 dengan 17 tahun (Adagrad)


Input(16 Tahun) & Output(Tahun 2018),  
RMSE: 0.78



Gambar A.1. 16 Prediksi 2018 dengan 16 tahun (Adagrad)




Input(31 Tahun) & Output(Tahun 2018),  
RMSE: 1.36




Gambar A.1. 17 Prediksi 2018 dengan 31 tahun (Adam)

Input(30 Tahun) & Output(Tahun 2018),  
RMSE: 1.11




Gambar A.1. 18 Prediksi 2018 dengan 30 tahun (Adam)

Input(29 Tahun) & Output(Tahun 18),  
RMSE: 0.98




Gambar A.1. 19 Prediksi 2018 dengan 29 tahun (Adam)

Input(28 Tahun) & Output(Tahun 18),  
RMSE: 1




Gambar A.1. 20 Prediksi 2018 dengan 28 tahun (Adam)

Input(27 Tahun) & Output(Tahun 2018),  
RMSE: 0.99



Gambar A.1. 21 Prediksi 2018 dengan 27 tahun (Adam)


Input(26 Tahun) & Output(Tahun 2018),  
RMSE: 0.81



Gambar A.1. 22 Prediksi 2018 dengan 26 tahun (Adam)




Input(25 Tahun) & Output(Tahun 18),  
RMSE: 0.48




Gambar A.1. 23 Prediksi 2018 dengan 25 tahun (Adam)

Input(24 Tahun) & Output(Tahun 18),  
RMSE: 0.86




Gambar A.1. 24 Prediksi 2018 dengan 24 tahun (Adam)

Input(23 Tahun) & Output(Tahun 2018),  
RMSE: 1.19




Gambar A.1. 25 Prediksi 2018 dengan 23 tahun (Adam)

Input(22 Tahun) & Output(Tahun 2018),  
RMSE: 1.07




Gambar A.1. 26 Prediksi 2018 dengan 22 tahun (Adam)

Input(21 Tahun) & Output(Tahun 2018),  
RMSE: 1.23



Gambar A.1. 27 Prediksi 2018 dengan 21 tahun (Adam)


Input(20 Tahun) & Output(Tahun 2018),  
RMSE: 1.25



Gambar A.1. 28 Prediksi 2018 dengan 20 tahun (Adam)




Input(19 Tahun) & Output(Tahun 2018),  
RMSE: 0.89




Gambar A.1. 29 Prediksi 2018 dengan 19 tahun (Adam)

Input(18 Tahun) & Output(Tahun 2018),  
RMSE: 0.79




Gambar A.1. 30 Prediksi 2018 dengan 18 tahun (Adam)

Input(17 Tahun) & Output(Tahun 2018),  
RMSE: 0.95



Gambar A.1. 31 Prediksi 2018 dengan 17 tahun (Adam)


Input(16 Tahun) & Output(Tahun 2018),  
RMSE: 0.89



Gambar A.1. 32 Prediksi 2018 dengan 16 tahun (Adam)

## A.2 Prediksi model untuk 6 dan 9 bulan

Input(29 Tahun) & Output(Jul - Des 2018),  
RMSE: 0.22



Gambar A.2. 1 Prediksi Juli - Desember 2018 dengan input 29 tahun (Adagrad)

Input(29 Tahun) & Output(Apr - Des 2018),  
RMSE: 0.4



Gambar A.2. 2 Prediksi April - Desember 2018 dengan input 29 tahun (Adagrad)




Input(28 Tahun) & Output(Jul - Des 2018),  
RMSE: 0.24




Gambar A.2. 3 Prediksi Juli - Desember 2018 dengan input 28 tahun (Adagrad)

Input(28 Tahun) & Output(Apr - Des 2018),  
RMSE: 0.47




Gambar A.2. 4 Prediksi April - Desember 2018 dengan input 28 tahun (Adagrad)

Input(27 Tahun) & Output(Jul - Des 2018),  
RMSE: 0.32




Gambar A.2. 5 Prediksi Juli - Desember 2018 dengan input 27 tahun (Adagrad)

Input(27 Tahun) & Output(Apr - Des 2018),  
RMSE: 0.3




Gambar A.2. 6 Prediksi April - Desember 2018 dengan input 27 tahun (Adagrad)

Input(25 Tahun) & Output(Jul - Des 2018),  
RMSE: 0.49



Gambar A.2. 7 Prediksi Juli - Desember 2018 dengan input 25 tahun (Adam)


Input(25 Tahun) & Output(Apr - Des 2018),  
RMSE: 0.29



Gambar A.2. 8 Prediksi April - Desember 2018 dengan input 25 tahun (Adam)




Input(26 Tahun) & Output(Jul - Des 2018),  
RMSE: 0.83




Gambar A.2. 9 Prediksi Juli - Desember 2018 dengan input 26 tahun (Adam)

Input(26 Tahun) & Output(Apr - Des 2018),  
RMSE: 0.4




Gambar A.2. 10 Prediksi April - Desember 2018 dengan input 26 tahun (Adam)

Input(18 Tahun) & Output(Jul - Des 2018),  
RMSE: 0.55



Gambar A.2. 11 Prediksi Juli - Desember 2018 dengan input 18 tahun (Adam)


Input(18 Tahun) & Output(Apr - Des 2018),  
RMSE: 0.36



Gambar A.2. 12 Prediksi April - Desember 2018 dengan input 18 tahun (Adam)


### A.3 Prediksi dengan tahun output yang berbeda (2014 & 2017)

Input(29 Tahun) & Output(2017),  
RMSE: 1.27



Gambar A.3. 1 Prediksi tahun 2017 dengan input 29 tahun (Adagrad)


Input(29 Tahun) & Output(2014),  
RMSE: 0.7



Gambar A.3. 2 Prediksi tahun 2014 dengan input 29 tahun (Adagrad)




Input(28 Tahun) & Output(2017),  
RMSE: 0.91



Gambar A.3. 3 Prediksi tahun 2017 dengan input 28 tahun (Adagrad)

Input(28 Tahun) & Output(2014),  
RMSE: 0.83




Gambar A.3. 4 Prediksi tahun 2014 dengan input 27 tahun (Adagrad)

Input(27 Tahun) & Output(2017),  
RMSE: 0.7




Gambar A.3. 5 Prediksi tahun 2017 dengan input 27 tahun (Adagrad)

Input(27 Tahun) & Output(2014),  
RMSE: 0.88




Gambar A.3. 6 Prediksi tahun 2014 dengan input 27 tahun (Adagrad)

Input(26 Tahun) & Output(2017),  
RMSE: 1.27



Gambar A.3. 7 6 Prediksi tahun 2017 dengan input 26 tahun (Adam)

Input(26 Tahun) & Output(2014),  
RMSE: 1.12



Gambar A.3. 8 Prediksi tahun 2014 dengan input 26 tahun (Adam)




Input(25 Tahun) & Output(2017),  
RMSE: 0.91




Gambar A.3. 9 Prediksi tahun 2017 dengan input 25 tahun (Adam)

Input(25 Tahun) & Output(2014),  
RMSE: 1.15




Gambar A.3. 10 Prediksi tahun 2014 dengan input 25 tahun (Adam)

Input(18 Tahun) & Output(2017),  
RMSE: 1.13



Gambar A.3. 11 Prediksi tahun 2017 dengan input 18 tahun (Adam)


Input(18 Tahun) & Output(2014),  
RMSE: 0.56



Gambar A.3. 12 Prediksi tahun 2014 dengan input 18 tahun (Adam)


## A.4 Prediksi kondisi ekstrim La Nina (2010-2011) dan El Nino (2015-2016)

Input(29 Tahun) & Output(2010 - 2011),  
RMSE: 1.22



Gambar A.4. 1 La Nina input 29 tahun prediksi 2010-2011 (Adagrad)


Input(28 Tahun) & Output(2010 - 2011),  
RMSE: 1.12



Gambar A.4. 2 La Nina input 28 tahun prediksi 2010-2011 (Adagrad)




Input(27 Tahun) & Output(2010 - 2011),  
RMSE: 1.17




Gambar A.4. 3 La Nina input 27 tahun prediksi 2010-2011 (Adagrad)

Input(29 Tahun) & Output(2015 - 2016),  
RMSE: 1.36




Gambar A.4. 4 El Nino input 29 tahun prediksi 2015-2016 (Adagrad)

Input(28 Tahun) & Output(2015 - 2016),  
RMSE: 1.49




Gambar A.4. 5 El Nino input 28 tahun prediksi 2015-2016 (Adagrad)

Input(27 Tahun) & Output(2015 - 2016),  
RMSE: 1.44




Gambar A.4. 6 El Nino input 27 tahun prediksi 2015-2016 (Adagrad)

Input(26 Tahun) & Output(2010 - 2011),  
RMSE: 1.59



Gambar A.4. 7 La Nina input 26 tahun prediksi 2010-2011 (Adam)

Input(25 Tahun) & Output(2010 - 2011),  
RMSE: 1.51



Gambar A.4. 8 La Nina input 25 tahun prediksi 2010-2011 (Adam)




Input(18 Tahun) & Output(2010 - 2011),  
RMSE: 1.73




Gambar A.4. 9 La Nina input 18 tahun prediksi 2010-2011 (Adam)

Input(26 Tahun) & Output(2015-2016),  
RMSE: 1.25




Gambar A.4. 10 El Nino input 26 tahun prediksi 2015-2016 (Adam)

Input(25 Tahun) & Output(2015-2016),  
RMSE: 1.22



Gambar A.4. 11 El Nino input 25 tahun prediksi 2015-2016 (Adam)

Input(18 Tahun) & Output(2015-2016),  
RMSE: 1.24



Gambar A.4. 12 El Nino input 18 tahun prediksi 2015-2016 (Adam)

## LAMPIRAN B

### KODE PROGRAM

```
# Core Tidyverse  
library(tidyverse)  
library(glue)  
library(forcats)  
library(data.table)
```

```
# Time Series  
library(timetk)  
library(tidyquant)  
library(tibbletime)  
library(lubridate)
```

```
# Visualization  
library(cowplot)  
library(plotly)
```

```
# Preprocessing  
library(recipes)  
library(reshape2)  
library(datasets)
```

```
# Sampling / Accuracy  
library(rsample)  
library(yardstick)
```

```
# Modeling  
library(keras)
```

```
#### Kode Pembuatan Model ####
```

```
predict_nino_34 <- function(data, epochs = 300, ...) {
```

```
  lstm_prediction <- function(data, epochs, ...) {
```



## # 5.1.2 Data Setup (MODIFIED)

```
df <- data
```

## # 5.1.3 Preprocessing

```
rec_obj_nino <- recipe(sst_nino34 ~ ., data = df) %>%
```

```
  step_sqrt(sst_nino3) %>%
```

```
  step_sqrt(sst_nino4) %>%
```

```
  step_sqrt(sst_nino34) %>%
```

```
  step_center(sst_nino3) %>%
```

```
  step_center(sst_nino4) %>%
```

```
  step_center(sst_nino34) %>%
```

```
  step_scale(sst_nino3) %>%
```

```
  step_scale(sst_nino4) %>%
```

```
  step_scale(sst_nino34) %>%
```

```
  prep()
```

```
df_processed_tbl <- bake(rec_obj_nino, df_nino)
```

```
center_history_34 <- rec_obj_nino$steps[[6]]$means["sst_nino34"]
```

```
scale_history_34 <- rec_obj_nino$steps[[9]]$sds["sst_nino34"]
```

## # 5.1.4 LSTM Plan

```
lag_setting <- 12 # = nrow(df_tst)
```

```
batch_size <- 12
```

```
train_length <- 324
```

```
tsteps <- 1
```

```
epochs <- epochs
```

## # 5.1.5 Train/Test Setup

```
# Training Set
```

```
lag_train_tbl_nino <- df_processed_tbl %>%
```

```
  mutate(value_lag_3 = lag(sst_nino3, n = lag_setting)) %>%
```

```
  mutate(value_lag_34 = lag(sst_nino34, n = lag_setting)) %>%
```



```

mutate(value_lag_4= lag( sst_nino4, n = lag_setting)) %>%
filter(!is.na(value_lag_3)) %>%
filter(!is.na(value_lag_34)) %>%
filter(!is.na(value_lag_4)) %>%
tail(train_length)

x_train_matrix <- cbind(lag_train_tbl_nino$value_lag_3,
lag_train_tbl_nino$value_lag_34, lag_train_tbl_nino$value_lag_4)
x_train_arr <- array(data = x_train_matrix, dim
c(nrow(x_train_matrix),3,1))
#x_train_arr <- matrix(data = x_train_vec, dim
c(length(x_train_vec), 1, 1))

y_train_vec <- lag_train_tbl_nino$sst_nino34
y_train_arr <- array(data = y_train_vec, dim
c(length(y_train_vec), 1))

# Testing Set
x_test_matrix <- x_train_matrix %>%
tail(lag_setting)
x_test_arr <- array(data = x_test_matrix, dim
c(length(x_test_vec), 3, 1))

model <- keras_model_sequential()

model %>%
layer_lstm(units = 50,
batch_size = batch_size,
input_shape = c(3,1),
return_sequences = TRUE,
stateful = TRUE) %>%
layer_lstm(units = 50,
return_sequences = FALSE,
stateful = TRUE) %>%
layer_dense(units = 1)

model %>%

```



```
compile(loss = 'mae', optimizer = 'adam')
```

### # 5.1.7 Fitting LSTM

```
for (i in 1:epochs) {  
  model %>% fit(x_train_arr,  
               y_train_arr,  
               batch_size = batch_size,  
               epochs = 1,  
               verbose = 1,  
               shuffle = FALSE)
```

```
  model %>% reset_states()  
  cat("Epoch: ", i)
```

### # 5.1.8 Predict and Return Tidy Data

```
# Make predictions
```

```
pred_out <- model %>%  
  predict(x_test_arr, batch_size = batch_size) %>%  
  [,1]
```

```
# Make future index using tk_make_future_timeseries()
```

```
idx <- data %>%  
  tk_index() %>%  
  tk_make_future_timeseries(n_future = lag_setting)
```

```
# Retransform values
```

```
pred_tbl_nino <- tibble(  
  index = idx,  
  sst_nino34 = (pred_out * scale_history_34 + center_history_34)^2  
)
```

```
# combine actual data with predictions
```

```
tbl_1 <- df %>%  
  select(index, sst_nino34) %>%  
  add_column(key = "actual")
```

```
tbl_3 <- pred_tbl_nino %>%
  add_column(key = "predict")
# Create time_bind_rows() to solve dplyr issue
time_bind_rows <- function(data_1, data_2, index) {
  index_expr <- enquo(index)
  bind_rows(data_1, data_2) %>%
    as_tbl_time(index = !! index_expr)
}
ret <- list(tbl_1, tbl_3) %>%
  reduce(time_bind_rows, index = index) %>%
  arrange(key, index) %>%
  mutate(key = as_factor(key))
return(ret)
}
safe_lstm <- possibly(lstm_prediction, otherwise = NA)
safe_lstm(data, epochs, ...)
```

#### Kode Pembuatan Plot ####

```
plot_prediction_nino <- function(data, id, alpha = 1, size = 0.5,
base_size = 14) {
```

```
  source("nino34_mean_index.R")
```

```
  g <- data %>%
```

```
    mutate(sst_oni = data[[2]]-nino34_mean_index) %>%
```

```
    ggplot(aes(index, sst_oni, color = key)) +
```

```
    geom_hline(yintercept = 1, size = 0.3, colour = "orange2", alpha =
```

```
0.5) +
```

```
  theme_minimal()
}
```





```
geom_hline(yintercept = 1.5, size = 0.5, colour = "orangered2",
alpha = 0.5) +
geom_hline(yintercept = 2, size = 0.7, colour = "red", alpha = 0.5) +
geom_hline(yintercept = -1, size = 0.3, colour = "cyan3", alpha =
0.5) +
geom_hline(yintercept = -1.5, size = 0.7, colour = "dodgerblue",
alpha = 0.5) +
geom_hline(yintercept = -2, size = 0.7, colour = "blue4", alpha =
0.5) +
annotate("text", label = "Weak", x = as.Date("2020-01-01"), y =
0.8, size = 4, color = "orange2") +
annotate("text", label = "Moderate", x = as.Date("2020-01-01"), y
= 1.2, size = 4, color = "orangered2") +
annotate("text", label = "Strong", x = as.Date("2020-01-01"), y =
1.7, size = 4, color = "red") +
annotate("text", label = "Very Strong", x = as.Date("2020-01-01"),
y = 2.2, size = 4, color = "black") +
annotate("text", label = "Weak", x = as.Date("2020-01-01"), y = -
0.8, size = 4, color = "cyan3") +
annotate("text", label = "Moderate", x = as.Date("2020-01-01"), y
= -1.2, size = 4, color = "dodgerblue") +
annotate("text", label = "Strong", x = as.Date("2020-01-01"), y = -
1.7, size = 4, color = "blue4") +
annotate("text", label = "Very Strong", x = as.Date("2020-01-01"),
y = -2.2, size = 4, color = "black") +
geom_line(alpha = 0.8, size = size) +
geom_point(alpha = alpha, size = size) +
theme_tq(base_size = base_size) +
scale_color_tq() +
theme(legend.position = c(5,3)) +
labs(
title = glue("{id}"),
x = "", y = ""
)
return(g)
}
```



#### Kode Formula RMSE ####

```
calc_rmse_nino <- function(prediction_tbl) {
  rmse_calculation <- function(data) {
    data %>%
      spread(key = key, value = sst_nino34) %>%
      select(-index) %>%
      filter(!is.na(predict)) %>%
      rename(
        truth = actual,
        estimate = predict
      ) %>%
      rmse(truth, estimate)
  }
  safe_rmse <- possibly(rmse_calculation, otherwise = NA)
  safe_rmse(prediction_tbl)$estimate
}
```